Konzept für eine Datenvermehrung von Trainingsdatensätzen für ein Maschinenlern-Modell zur Vorhersage eines Zustands eines technischen Bauteils

Technisches Gebiet

Die vorliegende Erfindung bezieht sich auf Verfahren, Vorrichtungen und Computerprogrammen zum Erzeugen von Trainingsdatensätzen zum Trainieren eines Maschinenlern-Modells zur Vorhersage über einen Zustand eines technischen Bauteils, zum Trainieren eines solchen Maschinenlern-Modells, und zum Einsatz eines solchen Maschinenlern-Modells.

Hintergrund

Der vermehrte Einbau von Messtechnik zum Monitoring energietechnischer Anlagen und Betriebsmitteln führt zu großen Mengen an Normalzustandsmessungen und der gelegentlichen Erfassung von Fehlerzuständen. Diese Normal- und Fehlerzustandsmessungen ermöglichen den Einsatz von Diagnoseverfahren, die auf Supervised Machine Learning (ML), deutsch „Überwachtes maschinelles Lernen“ basieren. Der Erfolgsgrad dieser ML-Diagnosesysteme ist abhängig von der Qualität und Quantität der zur Verfügung stehenden Daten. Elektrische Betriebsmittel weisen allerdings eine hohe Zuverlässigkeit auf, sodass nur sehr wenige Daten von Fehlerzuständen zur Erstellung von Diagnosesystemen zur Verfügung stehen. Somit kann nicht das vollständige Potential der ML-Diagnosesysteme ausgeschöpft werden. Eine Möglichkeit, ML-Diagnosesysteme zu verbessern, ist der Verwendung von Datenvermehrungsmethoden (auch engl. „Data Augmentation“). Diese generieren synthetische Daten zur Vergrößerung des Trainingsdatensatzes. Bisherige Datenvermehrungsmethoden sind zumeist generische Methoden. Diese integrieren kein Wissen über die nachfolgende Diagnoseaufgabe in die synthetischen Daten.

Mit einer modellbasierten Datenvermehrung wurden in der Medizintechnik bereits erfolgreich synthetische Bilder für das Training von Maschinenlern-Modellen generiert, da nicht genügend Trainingsdaten zur Verfügung standen. Von Shuqiong Wu (Wu et al.: „Reconstructing 3D Lung Shape from a Single 2D Image during the Deaeration Deformation Process using Model-based Data Augmentation“ (2019)) wurde ein sogenanntes Convolutional Neural Network (Konvolutionelles Neuronales Netzwerk, CNN) trainiert, um aus 2D-Lungenbildern 3D-Lungenbilder zu erstellen. Dafür wurden Statistical Displacement Models

(Statistische Verdrängungsmodelle, SDMs) zur Erstellung von synthetischen 3D Lungenbildern verwendet. Es wurde dabei für jedes vorhandene Computertomographiebild ein SDM erzeugt. Anschließend konnten mit den Modellen 3D Lungenbildern erstellt werden, die einen unterschiedlichen Füllzustand der Lunge repräsentieren. Diese synthetischen Bilder werden anschließend zum Training der CNNs eingesetzt. Es wurde gezeigt, dass Einsatz der synthetischen Daten in der Maschinenlern-Modell-Erstellung den Prädiktionsfehler verringert.

Ähnlich wird bei Uzunova et al. (Training CNNs for Image Registration from Few Samples with Model-based Data Augmentation“ (2017)) vorgegangen. Dort werden sogenannte „statistical appearance models“ (statistische Erscheinungsbildmodelle) mit Bildern von medizinischen Bildern parametriert. Für die Aussehens- und Formparameterwerden Normalverteilungen angenommen. Durch Ziehen von Parametern aus den jeweiligen Normalverteilungen können neue Bilder erzeugt werden. Mit diesen Bildern können anschließend selbstlernende Verfahren trainiert werden.

Diese beiden Ansätze befassen sich jedoch nur mit bildbezogenen Anwendungen im medizinischen Bereich. Teilweise müssen mehrere Modelle zur Datengenerierung erstellt werden, was einen erhöhten Aufwand bedeutet. Die vorgestellten Verfahren bieten keine Möglichkeit synthetischer Fehlerzustandsdaten zu erzeugen. Zudem ist nicht beschrieben, wie mit Modellen umzugehen ist, die Eingangsgrößen benötigen. Weiterhin werden die generierten, synthetischen Daten direkt für das Training verwendet, sodass sich mögliche Fehler der Modellierung im endgültig genutzten Maschinenlern-Modellen niederschlagen können.

Zur Diagnose von Betriebsmitteln werden beispielsweise klassische Datenvermehrungsverfahren wie das Aufmodulieren von weißem Rauschen oder Zeitdehnung oder -streckungen angewendet (Li et al.: „Intelligent rotating machinery fault diagnosis based on deep learning using data augmentation” (2020)). Eine Alternative zu diesen Datenvermehrungsverfahren bieten Deep-Learning-Methoden, die generative Modelle einsetzen. Diese generativen Modelle haben den Vorteil, von Merkmalen zu lernen mit diesem Wissen synthetische Daten zu generieren. In der Diagnostik von mechanischen Bauteilen (Li et al.: „Intelligent rotating machinery fault diagnosis based on deep learning using data augmentation” (2020)) als auch bei der Detektion von Teilentladungen (Wu et al.: „Partial Discharge Data Augmentation of High Voltage Cables based on the Variable Noise Superposition and Generative Adversarial Network“ (2018)) werden mit selbstlernenden Datenvermehrungsverfahren verbesserte

Diagnoseergebnisse erreicht. Bei der Detektion von Heißpunkten in Schaltanlagen kann nur eine geringe Verbesserung mittels selbstlernender Datenvermehrungsverfahren nachgewiesen werden (Gitzel et al.: „Towards Robust ML-Algorithms for the Condition Monitoring of Switchgear“ (2019)). Allerdings sind die dafür verwendeten Datenvermehrungsmethoden generische Methoden und bieten so nicht die Möglichkeit zusätzliches Wissen in Form von physikalischen Modellen in die Datenvermehrung zu integrieren.

Es besteht der Bedarf nach einem verbesserten Ansatz zur Vermehrung von Daten zum Training von Maschinenlern-Modellen und zum entsprechenden Training und Einsatz von Maschinenlern-Modellen.

Zusammenfassung

Diesem Bedarf wird von dem Gegenstand der unabhängigen Ansprüche Rechnung getragen.

Ausführungsbeispiele der vorliegenden Offenbarung basieren auf der Erkenntnis, dass die Datenvermehrung dadurch verbessert werden kann, dass physikalische Modelle eines technischen Bauteils verwendet werden, um synthetische Daten zu erzeugen. Dabei ist ein physikalisches Modell ein Modell, das physikalische Zusammenhänge des technischen Bauteils abbildet. Im Allgemeinen kann mittels dieses physikalischen Modells über einen Computer das technische Bauteil simuliert und/oder berechnet werden. Anstatt die synthetischen Daten direkt aus den vorhandenen Daten abzuleiten, werden vielmehr Eingangsdaten und Modell-Parameterwerte des physikalischen Modells aus den Messdaten abgeleitet und genutzt, um synthetische Daten mit einer erhöhten Genauigkeit zu erzeugen. Beispielsweise wurden in der Energietechnik, und in anderen technischen Gebieten, physikalische Modelle von Betriebsmitteln entwickelt. Diese in eine Datenvermehrung zu integrieren kann zu einer weiteren Verbesserung von ML-Diagnosesystemen von energietechnischen Anlagen und Betriebsmitteln führen. Ausführungsbeispiele schaffen Verfahren, Vorrichtungen und Computerprogramme zum Erzeugen von Trainingsdatensätzen, zum Training eines Maschinenlern-Modells mittels solcher Trainingsdatensätze, und zum Einsatz eines solchen Maschinenlern-Modells, die auf diesen Erkenntnissen basieren.

Verschiedene Aspekte der vorliegenden Offenbarung beziehen sich auf ein computer-implementiertes Verfahren zum Erzeugen von Trainingsdatensätzen zum Trainieren eines

Maschinenlern-Modells zur Vorhersage über einen Zustand eines technischen Bauteils. Das Verfahren umfasst ein Erhalten einer Mehrzahl von Messdatensätzen über das technische Bauteil. Jeder Messdatensatz umfasst zumindest ein oder mehrere Ausgangs-Messdaten. Das Verfahren umfasst ferner ein Ermitteln von Modell-Parameterwerten von ein oder mehreren Modell-Parametern eines physikalischen Modells des technischen Bauteils basierend auf den ein oder mehreren Ausgangs-Messdaten der jeweiligen Messdatensätze. Das Verfahren umfasst ferner ein Bestimmen einer ersten Mehrzahl von Trainingsdatensätzen. Beispielsweise kann das Verfahren ein Durchführen einer ersten Mehrzahl von Simulationen des physikalischen Modells, um die erste Mehrzahl von Trainingsdatensätzen zu generieren. Basierend auf einer statistischen Verteilung der ermittelten Modell-Parameterwerte können ein oder mehrere Modell-Parameterwerte für die jeweilige Simulation der ersten Mehrzahl von Simulationen ausgewählt werden. Das Verfahren umfasst ferner ein Durchführen einer zweiten Mehrzahl von Simulationen des physikalischen Modells, um eine zweite Mehrzahl von Trainingsdatensätzen zu generieren. Basierend auf der statistischen Verteilung der ermittelten Modell-Parameterwerte werden ein oder mehrere Modell-Parameterwerte für die jeweilige Simulation ausgewählt. Für jede Simulation wird zumindest ein Modell-Parameterwert der Modell-Parameterwerte außerhalb eines Hauptbereichs der statistischen Verteilung der ermittelten Modell-Parameterwerte ausgewählt. Durch das Ermitteln der Modell-Parameterwerte kann das physikalische Modell genauer den Messdaten des Bauteils angeglichen werden, so dass die erzeugten Trainingsdaten den Messdaten ähnlicher werden. Durch die Auswahl zumindest eines Modell-Parameterwerts, der sich außerhalb des Hauptbereichs der statistischen Verteilung des oder der Modell-Parameterwerte liegt, kann oder können ein oder mehrere abnormale Zustände des Bauteils simuliert werden, um Trainingsdatensätze zu erzeugen, die einen oder mehrere solcher abnormalen Zustände abbilden, die in den Messdaten selten vorkommen. Hierdurch lässt sich eine Datenvermehrung durchführen, die Trainingsdaten erzeugt, die den Messdaten höchst ähnlich sind, und die insbesondere einen Mangel an Messdaten von abnormalen Zuständen ausgleichen können.

Beispielsweise können die erste Mehrzahl von Trainingsdatensätzen einen Normalzustand des technischen Bauteils und die zweite Mehrzahl von Trainingsdatensätzen einen oder mehrere abnormale Zustände des technischen Bauteils abbilden. In anderen Worten kann die zweite Mehrzahl von Simulationen durchgeführt werden, um gezielt Trainingsdatensätzen von abnormalen Zuständen des technischen Bauteils zu erzeugen.

Dabei kann das physikalische Modell dazu geeignet sein, um eine Simulation des Normalzustands und eine Simulation der ein oder mehreren abnormalen Zustände des Bauteils durchzuführen. Somit muss nur ein physikalisches Modell gepflegt werden, auch kann die Ermittlung der Modell-Parameterwerte für den Normal- und die ein oder mehreren abnormalen Zustände verwendet werden. Alternativ kann eine erste Version des physikalischen Modells genutzt werden, um die Simulation des Normalzustands und eine zweite Version des physikalischen Modells genutzt werden, um die Simulation der ein oder mehreren abnormalen Zustände des Bauteils durchzuführen. In diesem Fall kann besser auf die Eigenheiten des technischen Bauteils außerhalb des Normalzustands eingegangen werden und/oder das Modell für die Simulation des Normalzustands einfacher gestaltet werden.

Während manche physikalische Modelle ohne Eingangs-Daten auskommen, etwa weil sie durch eine im Modell abgebildete Bewegung oder andere Größe angeregt werden, basieren viele physikalische Modelle nicht nur auf Modell-Parameterwerten, sondern auch auf Eingangs-Daten. In verschiedenen Ausführungsbeispielen umfasst die Mehrzahl von Messdatensätzen daher ferner ein oder mehrere Eingangs-Messdaten. In diesem Fall können die Modell-Parameterwerte des physikalischen Modells ferner basierend auf den ein oder mehreren Eingangs-Messdaten ermittelt werden. Für die Simulationen, etwa die erste und/oder die zweite Mehrzahl von Simulationen, des physikalischen Modells können ferner basierend auf einer statistischen Verteilung der Eingangs-Messdaten ein oder mehrere Eingangs-Daten ausgewählt werden.

Das Verfahren basiert auf der statistischen Verteilung der ermittelten Modell-Parameterwerte des physikalischen Modells. Entsprechend kann das Verfahren ferner das Bestimmen der statistischen Verteilung der ermittelten Modell-Parameterwerte des physikalischen Modells umfassen. Insbesondere kann das Verfahren ein Bestimmen der statistischen Verteilung der ermittelten Modell-Parameterwerte des physikalischen Modells, durch Unterteilen der Mehrzahl von Messdatensätzen in eine Mehrzahl von Gruppen von Messdatensätzen, Ermitteln, für jede Gruppe von Messdatensätzen, von ein oder mehreren Modell-Parameterwerten des physikalischen Modells durch Minimierung eines Fehlers zwischen den ein oder mehreren Ausgangs-Messdaten der jeweiligen Gruppe von Messdatensätzen und entsprechenden mittels des physikalischen Modells erzeugten Ausgangsdaten, und Berechnen der statistischen Verteilung der basierend auf den verschiedenen Gruppen von Messdatensätzen ermittelten Modell-Parameterwerte umfassen. So kann die statistische Verteilung der Modell-

Parameterwerte über eine Unterteilung der Messdatensätze zusammengestellt werden. Dabei kann jede Gruppe von Messdatensätzen ein oder mehrere Messdatensätze umfassen.

In verschiedenen Ausführungsbeispielen kann der Hauptbereich der statistischen Verteilung der Modell-Parameterwerte basierend auf einer vorgegebenen Wahrscheinlichkeitsverteilung der Modell-Parameterwerte bestimmt werden, etwa basierend auf einer Normalverteilung oder einer Poisson-Verteilung der Modell-Parameterwerte. Entsprechend kann das Verfahren ein Bestimmen einer vorgegebenen Wahrscheinlichkeitsverteilung (etwa einer Normalverteilung oder einer Poisson-Verteilung) der Modell-Parameterwerte durch Fitting der statistischen Verteilung der ermittelten Modell-Parameterwerte auf die vorgegebenen Wahrscheinlichkeitsverteilung umfassen.

Entsprechend kann die Auswahl der Modell-Parameterwerte außerhalb des Hauptbereichs ausgestaltet werden. Beispielsweise kann für jede Simulation der zweiten Mehrzahl von Simulationen zumindest ein Modell-Parameterwert basierend auf einer vorgegebenen Mindestabweichung von einem Erwartungswert einer Normalverteilung der Modell-Parameterwerte ausgewählt werden. Beispielsweise kann die vorgegebene Mindestabweichung zumindest 2,5 Standardabweichungen betragen. Über die Normalverteilung und eine vorgegebene Abweichung von der Normalverteilung lassen sich Bereiche berechnen, die außerhalb des Hauptbereichs der statistischen Verteilung der Modell-Parameterwerte liegen und die sich dadurch dafür eignen, um einen abnormalen Zustand des technischen Bauteils zu simulieren.

Beispielsweise kann für jede Simulation der zweiten Mehrzahl von Simulationen ein Modell-Parameterwert außerhalb des Hauptbereichs der statistischen Verteilung der ermittelten Modell-Parameterwerte und andere Modell-Parameterwerte, sofern vorhanden, basierend auf der statistischen Verteilung der ermittelten Modell-Parameterwerte ausgewählt werden. Weist das physikalische Modell mehrere Modell-Parameter auf, so können beispielsweise alle außer einem Modell-Parameter „normale“ Parameter-Werte annehmen.

Alternativ oder zusätzlich können für zumindest eine Simulation der zweiten Mehrzahl von Simulationen zumindest zwei Modell-Parameterwerte außerhalb des Hauptbereichs der statistischen Verteilung der jeweiligen Modell-Parameterwerte ausgewählt werden. Dabei können die zumindest zwei Modell-Parameterwerte basierend auf einem vorbekannten Zusammenhang zwischen den zwei Modell-Parametern ausgewählt werden. Dies ermöglicht, mit

dem notwendigen Wissen, eine realistischere Modellierung von abnormalen Zuständen des technischen Bauteils.

Im Allgemeinen können für jede Simulation der ersten Mehrzahl von Simulationen die ein oder mehreren Modell-Parameterwerte entsprechend der statistischen Verteilung der ermittelten Modell-Parameterwerte ausgewählt werden. Diese bilden somit den Normalzustand des technischen Bauteils ab.

Das physikalische Modell kann beispielsweise dazu vorgesehen sein, um durch Durchführen einer Simulation basierend auf zumindest ein oder mehreren Modell-Parameterwerten, und optional ein oder mehreren Eingangsdaten, ein oder mehrere Ausgangsdaten zu erzeugen. Dadurch kann das physikalische Modell zur Generierung der Trainingsdatensätze verwendet werden.

Das Verfahren kann im Allgemeinen zur Erzeugung von Trainingsdaten zum Training von Maschinenlern-Modellen zur Vorhersage eines Zustands technischer Bauteile vieler Domänen verwendet werden, sofern für das jeweilige Bauteil ein physikalisches Modell ermittelt werden kann. Insbesondere kann das technische Bauteil eine Komponente einer Maschine oder einer technischen Anlage sein, etwa einer energietechnischen Anlage. In manchen Ausführungsbeispielen kann das technische Bauteil etwa ein elektrotechnisches Bauteil sein, wie etwa eines von einem Transformator, einem Laststufenschalter, einem Leistungsschalter, einem Trennschalter, einem Lasttrennschalter, einer Schaltanlage, einem Kabel, einer Muffe, einer Freileitung, einer Freileitungsarmatur und einer Hochspannungsdurchführung.

Verschiedene Aspekte der vorliegenden Offenbarung befassen sich ferner mit einem computer-implementierten Verfahren zum Trainieren eines Maschinenlern-Modells zur Vorhersage eines Zustands eines technischen Bauteils. Das Verfahren umfasst ein Erhalten einer ersten Mehrzahl von Trainingsdatensätzen und einer zweiten Mehrzahl von Trainingsdatensätzen. Die erste Mehrzahl von Trainingsdatensätzen und die zweite Mehrzahl von Trainingsdatensätzen sind basierend auf dem zuvor vorgestellten Verfahren erzeugt. Die erste Mehrzahl von Trainingsdatensätzen bilden einen Normalzustand des technischen Bauteils ab und die zweite Mehrzahl von Trainingsdatensätzen bilden einen oder mehrere abnormale Zustände des technischen Bauteils ab. Das Verfahren umfasst ferner ein Trainieren des Maschinenlern-Modells basierend auf der ersten Mehrzahl von Trainingsdatensätzen und basierend auf der zweiten

Mehrzahl von Trainingsdatensätzen. Somit können die mittels des zuvor genannten Verfahrens erzeugten Trainingsdatensätze verwendet werden, um ein entsprechendes Maschinenlern-Modell zu trainieren.

Das zuvor vorgestellte Verfahren zum Erzeugen von Trainingsdatensätzen wird im Allgemeinen genutzt, um bereits vorhandene Messdaten um synthetische Trainingsdatensätze zu erweitern, so dass eine größere Menge an Trainingsdatensätzen zum Training des Maschinenlern-Modells zur Verfügung steht. Somit kann das Verfahren zum Trainieren des Maschinenlern-Modells ferner ein Erhalten einer Mehrzahl von Messdatensätzen über das technische Bauteil umfassen. Dabei kann das Training des Maschinenlern-Modells ferner auf der Mehrzahl von Messdatensätzen basieren. Somit kann das Maschinenlern-Modell sowohl auf den erzeugten, synthetischen Trainingsdatensätzen als auch auf den gemessenen Trainingsdatensätzen trainiert werden.

Beispielsweise kann die Mehrzahl von Messdatensätzen um die erste und zweite Mehrzahl von Trainingsdatensätzen erweitert werden und das Maschinenlern-Modell gemeinsam basierend auf der Mehrzahl von Messdatensätzen und der ersten und zweiten Mehrzahl von Trainingsdatensätzen trainiert werden. Dies ermöglicht ein Training des Maschinenlern-Modells mit einem größeren Satz von Trainingsdaten.

Alternativ kann das Maschinenlern-Modell in einem ersten Schritt basierend auf der ersten und zweiten Mehrzahl von Trainingsdatensätzen trainiert werden, und das Training des Maschinenlern-Modells in einem zweiten Schritt mittels Transfer Learning basierend auf der Mehrzahl von Messdatensätzen fortgeführt werden. Damit kann beispielsweise ein Fein-Tuning auf unterschiedliche Instanzen des technischen Bauteils oder auf unterschiedliche technische Bauteile, die das gleiche physikalische Modell verwenden, ermöglicht werden. Dabei kann das vortrainierte Modell beispielsweise als „standalone feature extractor“ (selbstständiger Merkmals-Extrahierer), „integrated feature extractor“ (integrierter Merkmals-Extrahierer) oder für die Gewichts-Initialisierung verwendet werden, wie im Zusammenhang mit den Fign. 2a bis 2h vertiefend dargestellt wird.

Beispielsweise kann das Maschinenlern-Modell eine Mehrzahl von Schichten umfassen. Die Gewichte zumindest einer Schicht der Mehrzahl von Schichten kann während des Transfer Learning eingefroren sein. Damit ist es möglich, erst ein allgemeineres Modell zu generieren,

das anschließend basierend auf den Messdaten nachjustiert wird, da die relevanten Gewichte, die im Transfer Learning angepasst werden, im Allgemeinen in den Schichten, die näher zu einer Ausgabeschicht der Mehrzahl von Schichten angeordnet sind, zu finden sind.

Im Allgemeinen kann das Maschinenlern-Modell mittels Supervised Learning trainiert werden. Dabei können die erste und zweite Mehrzahl von Trainingsdatensätzen als Eingabedaten und die Zugehörigkeit der Trainingsdatensätze zu einer der ersten und zweiten Mehrzahl von Trainingsdatensätzen als erwünschte Ausgabedaten für das Training verwendet werden. Beispielsweise kann die Zugehörigkeit zu den Trainingsdatensätzen als Zielwert für einen Klassifikator verwendet werden.

In verschiedenen Ausführungsbeispielen wird das Maschinenlern-Modell als Klassifikator für den Zustand des technischen Bauteils trainiert. Beispielsweise kann das Maschinenlern-Modell trainiert werden, um basierend auf einen Datensatz (oder mehreren Datensätzen) mit Messdaten den Zustand des technischen Bauteils in eine der Klassifikationen Normalzustand und Fehlerzustand einzuteilen. Alternativ kann das Maschinenlern-Modell trainiert werden, um basierend auf einen Datensatz (oder mehreren Datensätzen) mit Messdaten den Zustand des technischen Bauteils in eine der Klassifikationen Normalzustand, Vor-Fehlerzustand und Fehlerzustand einzuteilen. Alternativ kann das Maschinenlern-Modell trainiert werden, um basierend auf einen Datensatz (oder mehreren Datensätzen) mit Messdaten einen Zustand des technischen Bauteils in zumindest eine der Klassifikationen Normalzustand, erster Fehlerzustand und zweiter Fehlerzustand einzuteilen. Auch Mischformen sind möglich, etwa zur Klassifikation in die Klassen Normalzustand, ein oder mehrere abnormale Zustände (etwa Vor-Fehlerzustände) und ein oder mehrere Fehlerzustände.

Verschiedene Aspekte der vorliegenden Offenbarung befassen sich ferner mit einem computer-implementierten Verfahren zum Vorhersagen eines Zustands eines technischen Bauteils. Das Verfahren umfasst ein Erhalten eines Messdatensatzes über das technische Bauteil. Das Verfahren umfasst ein Bereitstellen von Messdaten des Messdatensatzes für ein Maschinenlern-Modell, wobei das Maschinenlern-Modell gemäß dem zuvor genannten Verfahren trainiert ist. Das Verfahren umfasst ferner ein Vorhersagen des Zustands des technischen Bauteils basierend auf einer Ausgabe des Maschinenlern-Modells. Dies stellt die Anwendung des Maschinenlern-Modells dar, das basierend auf der vorgestellten Datenvermehrung trainiert wurde.

Verschiedene Aspekte der vorliegenden Offenbarung befassen sich ferner mit einem System umfassend ein technisches Bauteil und eine computerimplementierte Vorrichtung. Die computerimplementierte Vorrichtung umfasst ein oder mehrere Prozessoren und ein oder mehreren Speichereinrichtungen und ist ausgebildet zum Ausführen des Verfahrens zum Vorhersagen eines Zustands eines technischen Bauteils. Dabei ist die computerimplementierte Vorrichtung ausgebildet, um den Zustand des technischen Bauteils vorherzugsagen.

Verschiedene Aspekte der vorliegenden Offenbarung befassen sich ferner mit einem Programm mit einem Programmcode zum Durchführen zumindest eines der zuvor vorgestellten Verfahren, wenn der Programmcode auf einem Computer, einem Prozessor, einem Kontrollmodul oder einer programmierbaren Hardwarekomponente ausgeführt wird.

Verschiedene Aspekte der vorliegenden Offenbarung befassen sich ferner mit einer computerimplementierten Vorrichtung mit ein oder mehreren Prozessoren und ein oder mehreren Speichereinrichtungen, ausgebildet zum Durchführen zumindest eines der vorgestellten Verfahren.

Figurenkurzbeschreibung

Einige Beispiele von Vorrichtungen und/oder Verfahren werden nachfolgend bezugnehmend auf die beiliegenden Figuren lediglich beispielhaft näher erläutert. Es zeigen:

Fig. 1a ein Flussdiagramm eines Beispiels eines computer-implementierten Verfahrens zum Erzeugen von Trainingsdatensätzen zum Trainieren eines Maschinenlern-Modells zur Vorhersage über einen Zustand eines technischen Bauteils;

Fig. 1b ein Blockdiagramm eines Beispiels einer computer-implementierten Vorrichtung zum Erzeugen von Trainingsdatensätzen zum Trainieren eines Maschinenlern-Modells zur Vorhersage über einen Zustand eines technischen Bauteils;

Fig. 1c ein schematisches Diagramm einer grundlegenden Verfahrensweise einer modellbasierten Datenvermehrung;

Fig. 1d ein schematisches Diagramm eines Beispiels zur Erzeugung von Trainingsdatensätzen, die einen Normalzustand eines technischen Bauteils abbilden;

Fig. 1e ein Diagramm einer Wahrscheinlichkeitsverteilung und einer basierend auf der Wahrscheinlichkeitsverteilung ausgeführten Auswahl eines Modell-Parameters;

Fig. 1f ein Diagramm eines Beispiels eines Ermittelns von Modell-Parameterwerten für ein physikalisches Modell eines Transformators;

Fig. 2a ein Flussdiagramm eines Beispiels eines computer-implementierten Verfahrens zum Trainieren eines Maschinenlern-Modells zur Vorhersage eines Zustands eines technischen Bauteils;

Fig. 2b ein Blockdiagramm eines Beispiels einer computer-implementierten Vorrichtung zum Trainieren eines Maschinenlern-Modells zur Vorhersage eines Zustands eines technischen Bauteils;

Fign. 2c und 2d zwei Beispiele einer Vermischung von Messtrainingsdaten und synthetischen Trainingsdaten;

Fig. 2e ein Beispiel eines Transfer Learning-Ansatzes;

Fig. 2f ein Beispiel eines Transfer Learning-Ansatzes, der auf einer Feineinstellung des Maschinenlern-Modells basiert;

Fig. 2g ein Beispiel eines Transfer Learning-Ansatzes, der auf einer Merkmalsextraktion basiert;

Fig. 3a ein Flussdiagramm eines Beispiels eines computer-implementierten Verfahrens zum Vorhersagen eines Zustands eines technischen Bauteils; und

Fig. 3b ein Blockdiagramm eines Beispiels einer computer-implementierten Vorrichtung zum Vorhersagen eines Zustands eines technischen Bauteils und eines Systems.

Beschreibung

Einige Beispiele werden nun ausführlicher Bezug nehmend auf die beiliegenden Figuren beschrieben. Weitere mögliche Beispiele sind jedoch nicht auf die Merkmale dieser detailliert beschriebenen Ausführungsformen beschränkt. Diese können Modifikationen der Merkmale sowie Entsprechungen und Alternativen zu den Merkmalen aufweisen. Ferner soll die Terminologie, die hierin zum Beschreiben bestimmter Beispiele verwendet wird, nicht einschränkend für weitere mögliche Beispiele sein.

Gleiche oder ähnliche Bezugszeichen beziehen sich in der gesamten Beschreibung der Figuren auf gleiche oder ähnliche Elemente beziehungsweise Merkmale, die jeweils identisch oder auch in abgewandelter Form implementiert sein können, während sie die gleiche oder eine ähnliche Funktion bereitstellen. In den Figuren können ferner die Stärken von Linien, Schichten und/oder Bereichen zur Verdeutlichung übertrieben sein.

Wenn zwei Elemente A und B unter Verwendung eines „oder“ kombiniert werden, ist dies so zu verstehen, dass alle möglichen Kombinationen offenbart sind, d. h. nur A, nur B sowie A und B, sofern nicht im Einzelfall ausdrücklich anders definiert. Als alternative Formulierung für die gleichen Kombinationen kann „zumindest eines von A und B“ oder „A und/oder B“ verwendet werden. Das gilt Äquivalent für Kombinationen von mehr als zwei Elementen.

Wenn eine Singularform, z. B. „ein, eine“ und „der, die, das“ verwendet wird und die Verwendung nur eines einzelnen Elements weder explizit noch implizit als verpflichtend definiert ist, können weitere Beispiele auch mehrere Elemente verwenden, um die gleiche Funktion zu implementieren. Wenn eine Funktion im Folgenden als unter Verwendung mehrerer Elemente implementiert beschrieben ist, können weitere Beispiele die gleiche Funktion unter Verwendung eines einzelnen Elements oder einer einzelnen Verarbeitungsentität implementieren. Es versteht sich weiterhin, dass die Begriffe „umfasst“, „umfassend“, „aufweist“ und/oder „aufweisend“ bei deren Gebrauch das Vorhandensein der angegebenen Merkmale, Ganzzahlen, Schritte, Operationen, Prozesse, Elemente, Komponenten und/oder einer Gruppe derselben beschreiben, dabei aber nicht das Vorhandensein oder das Hinzufügen eines oder mehrerer anderer Merkmale, Ganzzahlen, Schritte, Operationen, Prozesse, Elemente, Komponenten und/einer Gruppe derselben ausschließen.

Verschiedene Ausführungsbeispiele der vorliegenden Offenbarung befassen sich mit einer modellbasierten Datenvermehrung, die es erlaubt, Betriebsmittelmodelle, das heißt physikalische Modelle eines Betriebsmittels, welches ein technisches Bauteil ist, in die Datenvermehrung zu integrieren.

Fig. 1a zeigt ein Flussdiagramm eines Beispiels eines computer-implementierten Verfahrens zum Erzeugen von Trainingsdatensätzen zum Trainieren eines Maschinenlern-Modells zur Vorhersage über einen Zustand eines technischen Bauteils. Das Verfahren umfasst ein Erhalten 110 einer Mehrzahl von Messdatensätzen über das technische Bauteil. Jeder Messdatensatz umfasst zumindest ein oder mehrere Ausgangs-Messdaten. Das Verfahren umfasst ferner ein Ermitteln 120 von Modell-Parameterwerten von ein oder mehreren Modell-Parametern eines physikalischen Modells des technischen Bauteils basierend auf den ein oder mehreren Ausgangs-Messdaten der jeweiligen Messdatensätze. Das Verfahren umfasst ferner ein Bestimmen 140 einer ersten Mehrzahl von Trainingsdatensätzen. Beispielsweise kann das Verfahren ein (optionales) Durchführen einer ersten Mehrzahl von Simulationen des physikalischen Modells, um die erste Mehrzahl von Trainingsdatensätzen zu generieren. Basierend auf einer statistischen Verteilung der ermittelten Modell-Parameterwerte können ein oder mehrere Modell-Parameterwerte für die jeweilige Simulation der ersten Mehrzahl von Simulationen ausgewählt werden. Alternativ oder zusätzlich können die Messdatensätze als erste Mehrzahl von Trainingsdatensätzen verwendet werden. In diesem Fall sind die erste Mehrzahl von Trainingsdatensätze nicht synthetisch. Das Verfahren umfasst ferner ein Durchführen 150 einer zweiten Mehrzahl von Simulationen des physikalischen Modells, um eine zweite Mehrzahl von Trainingsdatensätzen zu generieren. Basierend auf der statistischen Verteilung der ermittelten Modell-Parameterwerte werden ein oder mehrere Modell-Parameterwerte für die jeweilige Simulation ausgewählt. Für jede Simulation wird zumindest ein Modell-Parameterwert außerhalb eines Hauptbereichs der statistischen Verteilung der ermittelten Modell-Parameterwerte ausgewählt. Optional umfasst das Verfahren ferner ein Bereitstellen (etwa ein Ausgeben) der ersten Mehrzahl und/oder der zweiten Mehrzahl von Trainingsdatensätzen, etwa über eine Schnittstelle oder über eine Speichereinrichtung.

Fig. 1b zeigt ein Blockdiagramm eines Beispiels einer entsprechenden computer-implementierten Vorrichtung zum Erzeugen von Trainingsdatensätzen zum Trainieren eines Maschinenlern-Modells zur Vorhersage über einen Zustand eines technischen Bauteils. Die Vorrichtung 10 umfasst ein oder mehreren Prozessoren 14 und ein oder mehreren

Speichereinrichtungen 16. Optional umfasst die Vorrichtung 10 ferner eine Schnittstelle 12. Die Vorrichtung 10 ist ausgebildet zum Durchführen zumindest des Verfahrens von Fig. 1a. Optional kann die Vorrichtung 10 ferner ausgebildet sein, um das Verfahren von Fig. 2a und/oder das Verfahren von Fig. 3a auszuführen. Dabei wird die Funktionalität der Vorrichtung 10 von den ein oder mehreren Prozessoren 14 der Vorrichtung bereitgestellt, unter Zuhilfenahme der optionalen Schnittstelle 12 (etwa zum Erhalten der Messdatensätze und zur Ausgabe der Trainingsdatensätze) und der ein oder mehreren Speichereinrichtungen (etwa zum Speichern der Messdatensätze, der Trainingsdatensätze und des physikalischen Modells).

Die folgende Beschreibung bezieht sich sowohl auf das Verfahren von Fig. 1a als auch auf ein entsprechendes Computerprogramm und die entsprechende Vorrichtung von Fig. 1b. Merkmale, die im Zusammenhang des Verfahrens eingeführt werden, können daher auch in die entsprechende Vorrichtung und das Computerprogramm übernommen werden (und umgekehrt).

Die grundlegende Vorgehensweise eines Beispiels der modellbasierten Datenvermehrung, wie sie durch das vorgeschlagene Verfahren, das entsprechende Computerprogramm und die entsprechende Vorrichtung durchgeführt werden, ist in Abbildung 1c dargestellt. Fig. 1c zeigt ein schematisches Diagramm einer grundlegenden Verfahrensweise einer modellbasierten Datenvermehrung.

Die modellbasierte Datenvermehrung basiert auf drei Kernbausteinen: einem Modell des Betriebsmittels (d.h. des technischen Bauteils), einem Algorithmus zum Ermitteln der Modell-Parameterwerte des physikalischen Modells (etwa zur Parameteroptimierung des Modells) und der Generierung von Parameterkombinationen des Modells. Durch das Modell kann zusätzliches Wissen über die zu diagnostizierende Komponente und Messgrößenzusammenhänge integriert werden. Mit dem Algorithmus zum Ermitteln der Modell-Parameterwerte kann das Modell an Messdaten gefittet werden, um so den Fehler zwischen Modellausgang und Messdatensätzen zu minimieren. Mit diesem Algorithmus und den vorhandenen Messungen wird beispielsweise eine Datenbank der Parameter des Modells erstellt, indem das Modell mehrfach an unterschiedliche Messungen gefittet wird. Wie in Fig. 1c gezeigt wird, werden Messungen, d.h. Messdatensätze, als Eingabe der Parameteroptimierung des physikalischen Modells genutzt. Dabei sind die Bezeichnungen „Optimierung“ und „Minimierung“ nicht

absolut zu verstehen – Ziel ist es, die Werte im Rahmen einer Optimierung zu verbessern und nicht zwangsläufig den einen optimalen Wert zu ermitteln. Auch ist es Ziel, den Fehler im Rahmen einer Minimierung zu reduzieren; dabei ist es nicht zwangsläufig das Ziel, den einen minimalen Wert zu ermitteln.

Aus dieser Parameterdatenbank generiert ein weiterer Algorithmus („Parametrierungsalgorithmus“ in Fig. 1c) Parameterkombinationen für die erste und zweite Mehrzahl von Simulationen, also für Normal- und abnormale Zustände, wie etwa Fehlerzustände. Mit diesen Parametern wird das Modell parametriert und im Rahmen der ersten und zweiten Mehrzahl von Simulationen simuliert. Somit können synthetische Daten, etwa die erste und zweite Mehrzahl von Trainingsdatensätzen, erzeugt werden. Welche Modell-Parameter, ob alle oder eine Teilmenge verwendet wird, kann vom Anwender festgelegt werden. Darüber hinaus wurden Möglichkeiten entwickelt, wie die synthetischen Daten der modellbasierten Datenvermehrung für die Erstellung von Maschinenlern-Modellen verwendet werden können, was im Zusammenhang mit den Fign. 2a bis 2g erläutert wird.

Physikalische Modelle stellen Systeme in der Regel vereinfacht dar und vernachlässigen dabei einige interne oder externe Einflüsse wie z. B. Temperatureinflüsse. Infolgedessen zeigen Messungen des realen Systems eine Streuung, die durch das physikalische Modell nicht dargestellt wird. Die modellbasierte Datenvermehrung bildet diese Streuung ab, da sie für die korrekte Unterscheidung zwischen Abnormal- und Normalzustand notwendig ist. Die modellbasierte Datenvermehrung verwendet eine wahrscheinlichkeitsbasierte Parameterauswahl des physikalischen Modells, um die in den Messungen gefundenen Streuungen darzustellen. Abnormal- oder Fehlerzustände werden dabei durch Manipulation der Wahrscheinlichkeitsverteilungen der ausgewählten Parameter simuliert.

Zur Erstellung der dafür benötigten statistischen Verteilung der Modell-Parameterwerte, und, optional, einer statistischen Verteilung von Eingangsdaten des physikalischen Modells, werden die Messdatensätze ausgewertet. Dabei umfasst jeder Messdatensatz zumindest ein oder mehrere Ausgangs-Messdaten. Optional umfasst die Mehrzahl von Messdatensätzen ferner ein oder mehrere Eingangs-Messdaten. Dabei sind die Messdatensätze, wie dem Namen zu entnehmen ist, Datensätze, die auf Messungen (im Folgenden auch Observationen genannt) basieren. Dabei ist eine Vielzahl von verschiedenen Messdaten denkbar. Beispielsweise können die Messdaten (d.h. die Eingangs-Messdaten und/oder die Ausgangsmessdaten) ein oder

mehrere von Messdaten eines Stromsensors, Messdaten eines Spannungssensors, Messdaten eines Audio-Sensors (etwa eines Analog-Digital-Wandlers, der ein Mikrofonsignal wandelt), Messdaten eines Vibrations-Sensors, Messdaten (etwa Bilddaten) einer Kamera (etwa einer Wärmebildkamera), Messdaten eines Temperatursensors, Messdaten eines Wettersensors, Messdaten eines Drehzahlsensors und Messdaten eines Kraftsensors umfassen. Die Messdaten können dabei vorverarbeitet sein, d.h., Filter können auf die Messdaten angewandt sein und/oder eine mathematische Transformation kann auf die Messdaten angewandt sein. Beispielsweise können bei einer Vibrationsmessung Vibrationen einer bestimmten Frequenz isoliert sein und die jeweiligen Messdaten bilden. Dabei entsprechen die Ausgangs-Messdaten Messdaten, die an einem Ausgang des technischen Bauteils gemessen werden oder die eine Beobachtung über das technische Bauteil darstellen, etwa eine Bewegung des technischen Bauteils oder ein Stromverbrauch des technischen Bauteils. Die Eingangs-Messdaten entsprechen Messdaten von Mitteln dar, die einen Einfluss auf das technische Bauteil nehmen. Im Falle des im Rahmen von Fig. 1g behandelten Transformators können die Ausgangs-Messdaten beispielsweise der Schwingungsamplitude A_{100hz} entsprechen, die durch einen Audio-Sensor oder einen Vibrationssensor gemessen werden kann, während die Eingangs-Messdaten beispielsweise dem Strom i und der Spannung u entsprechen können. Diese Messdaten der Messdatensätze werden verwendet, um die Modell-Parameterwerte des physikalischen Modells zu ermitteln, d.h., die generischen Modell-Parameterwerte des physikalischen Modells zu anzupassen, dass sie möglichst genau ein entsprechendes technisches Bauteil abbilden, an dem die Messdaten gewonnen wurden. Dabei bilden die Mehrzahl von Messdatensätzen beispielsweise einen Normalzustand des technischen Bauteils ab, so dass auf dieser Basis sowohl Trainingsdatensätze, die den Normalzustand abbilden als auch Trainingsdatensätze, die einen abnormalen Zustand abbilden, gewonnen werden können.

Das Verfahren umfasst daher das Ermitteln 120 der Modell-Parameterwerte der ein oder mehreren Modell-Parameter des physikalischen Modells des technischen Bauteils basierend auf den ein oder mehreren Ausgangs-Messdaten der jeweiligen Messdatensätze, und optional basierend auf den ein oder mehreren Eingangs-Messdaten ermittelt. Dies kann beispielsweise durch Lösen eines Gleichungssystems des physikalischen Modells, basierend auf den Ausgangs-Messdaten und optional den Eingangs-Messdaten geschehen. Dabei ist es das Ziel, die Modell-Parameterwerte so zu wählen, dass Ausgangsdaten des physikalischen Modells möglichst genau den Ausgangs-Messdaten der Messdatensätzen entsprechen (etwa wenn das physikalische Modell mit den entsprechenden Eingangs-Messdaten als Eingangsdaten simuliert

wird). In anderen Worten werden die Modell-Parameterwerte so gewählt, dass der Fehler zwischen den Ausgangsdaten des physikalischen Modells und den Ausgangsmessdaten reduziert/minimiert werden. Beispielsweise kann das physikalische Modell in einer numerischen Simulation berechnet werden, oder, wenn das physikalischen Modell einer Formel entspricht, die die physikalischen Zusammenhänge abbildet, kann die Formel berechnet werden.

In dem vorgeschlagenen Konzept basiert die Parametrierung auf einer statistischen Verteilung der Modell-Parameterwerte des physikalischen Modells. Entsprechend kann das Verfahren ein Bestimmen 122 der statistischen Verteilung der ermittelten Modell-Parameterwerte des physikalischen Modells umfassen. Insofern kann beispielsweise nicht nur ein Modell-Parameterwert oder ein Satz von Modell-Parameterwerten ermittelt werden. Vielmehr können, basierend auf der Mehrzahl von Messdatensätzen, eine Mehrzahl verschiedener Modell-Parameterwerte oder verschiedener Sätze von Modell-Parameterwerten ermittelt werden. Daraufhin kann eine statistische Auswertung basierend auf der Mehrzahl verschiedener Modell-Parameterwerte oder verschiedener Sätze von Modell-Parameterwerten durchgeführt werden. Das Bestimmen 122 der statistischen Verteilung der ermittelten Modell-Parameterwerte des physikalischen Modells kann daher, beispielsweise, durch Unterteilen 124 der Mehrzahl von Messdatensätzen in eine Mehrzahl von Gruppen von Messdatensätzen, Ermitteln 120, für jede Gruppe von Messdatensätzen, von ein oder mehreren Modell-Parameterwerten des physikalischen Modells durch Minimierung des Fehlers zwischen den ein oder mehreren Ausgangs-Messdaten der jeweiligen Gruppe von Messdatensätzen und entsprechenden mittels des physikalischen Modells erzeugten Ausgangsdaten, und Berechnen 126 der statistischen Verteilung der basierend auf den verschiedenen Gruppen von Messdatensätzen ermittelten Modell-Parameterwerte durchgeführt werden. Dabei kann jede Gruppe von Messdatensätzen ein oder mehrere Messdatensätze umfassen.

In manchen Beispielen kann die statistische Verteilung der Modell-Parameterwerte, etwa für die zweite Mehrzahl von Simulationen, in eine vorgegebene Wahrscheinlichkeitsverteilung überführt werden, etwa in eine Normalverteilung oder eine Poissonverteilung. Entsprechend kann das Verfahren ein Bestimmen einer 128 vorgegebenen Wahrscheinlichkeitsverteilung der Modell-Parameterwerte, etwa einer Normalverteilung oder einer Poissonverteilung der Modell-Parameterwerte, durch Fitting der statistischen Verteilung der ermittelten Modell-Parameterwerte auf die vorgegebenen Wahrscheinlichkeitsverteilung umfassen.

Basiert das physikalische Modell auf Eingangsdaten, die im Rahmen der Simulationen als Parameter übergeben werden, so kann auch die statistische Verteilung der entsprechenden Eingangs-Messdaten ermittelt werden. Beispielsweise kann das Verfahren ferner ein Bestimmen 130 der statistischen Verteilung der Eingangs-Messdaten umfassen. Wiederum kann für die Eingangs-Messdaten eine vorgegebene Wahrscheinlichkeitsverteilung verwendet werden, etwa Normalverteilungen, multivariate Normalverteilungen, Chi-Quadrat-Verteilungen, Betaverteilungen, Dreiecksverteilungen usw. Das Verfahren kann daher ferner ein Fitting der statistischen Verteilung der Eingangs-Messdaten auf eine vorgegebene Wahrscheinlichkeitsverteilung umfassen.

Die Datenvermehrung des Normalzustandsdaten basiert auf dem Modell des zu diagnostizierenden Systems (d.h. dem physikalischen Modell), einem Algorithmus zur Modell-Parameteridentifikation anhand von Messungen und einer Parameterwerteziehung. Das Verfahren umfasst das Durchführen 140 der ersten Mehrzahl von Simulationen des physikalischen Modells, um die erste Mehrzahl von Trainingsdatensätzen zu generieren. Dabei ist das physikalische Modell dazu vorgesehen ist, um durch Durchführen einer Simulation basierend auf zumindest ein oder mehreren Modell-Parameterwerten, und, optional, ein oder mehreren Eingabedaten, ein oder mehrere Ausgangsdaten zu erzeugen. Dabei kann das physikalische Modell dazu geeignet sein, um eine Simulation des Normalzustands (d.h. die erste Mehrzahl von Simulationen) und eine Simulation der ein oder mehreren abnormalen Zustände (d.h. die zweite Mehrzahl von Simulationen) des Bauteils durchzuführen. Alternativ kann eine erste Version des physikalischen Modells für die erste Mehrzahl von Simulationen und eine zweite Version des physikalischen Modells, die von der ersten Version verschieden ist, für die zweite Mehrzahl von Simulationen verwendet werden. Das Durchführen der Simulationen (der ersten und zweiten Mehrzahl von Simulationen) kann durch Durchführen einer numerischen Simulation oder durch Berechnen einer Formel erfolgen, die die physikalischen Zusammenhänge abbildet.

Basierend auf der statistischen Verteilung der ermittelten Modell-Parameterwerte (die jeweils auf eine vorgegebene Wahrscheinlichkeitsverteilung gefittet sein können, wie etwa Normalverteilungen, multivariate Normalverteilungen, Chi-Quadrat-Verteilungen, Betaverteilungen, Dreiecksverteilungen) werden ein oder mehrere Modell-Parameterwerte für die jeweilige Simulation ausgewählt. Optional werden, sofern in dem physikalischen Modell vorgesehen, ferner basierend auf der statistischen Verteilung der Eingangs-Messdaten ein oder mehrere

Eingangs-Daten ausgewählt. In anderen Worten kann das Verfahren ferner ein Auswählen der ein oder mehrere Modell-Parameterwerte, und, optional, der ein oder mehreren Eingangs-Parameter, für die jeweilige Simulation umfassen. Dabei kann für jede Simulation der ersten Mehrzahl von Simulationen die ein oder mehreren Modell-Parameterwerte, und, optional, die ein oder mehreren Eingangsdaten, entsprechend der statistischen Verteilung der ermittelten Modell-Parameterwerte oder der statistischen Verteilung der Eingangs-Messdaten ausgewählt werden. Dabei werden die Modell-Parameterwerte, und optional, Eingangsdaten des physikalischen Modells, basierend auf dem Algorithmus zur Modell-Parameteridentifikation anhand von Messungen (wie bereits eingeführt) und der Parameterwerteziehung ausgewählt.

Fig. 1d zeigt ein schematisches Diagramm eines Beispiels zur Erzeugung von Trainingsdatensätzen, die einen Normalzustand eines technischen Bauteils abbilden. Für die Simulation des Modells aus Fig. 1d werden sowohl Eingangsgrößen als auch Modell-Parameterwerte verwendet. Beide werden in bei der modellbasierten Datenvermehrung des Normalzustands über eine statistische Ziehung ermittelt. Dafür werden die Wahrscheinlichkeitsverteilungen (d.h. die statistischen Verteilungen) der Eingangsgrößen und Parameterwerte des Modells ermittelt. Der Ablauf der Erzeugung synthetischer Normalzustandsdaten ist in Fig. 1d gezeigt.

Es sind n Stichprobenmessungen (d.h. Messdatensätze oder Observationen) des Normalzustands vorhanden, die für die Datenvermehrung genutzt werden. Aus den Messungen kann für jede Eingangsgröße jeweils eine Wahrscheinlichkeitsverteilung identifiziert werden (Block „Identifikation der Eingangsgrößenverteilungen“ mit zwei exemplarischen Eingangsgrößenwerten E_1 und E_2). Für die Identifikation der Wahrscheinlichkeitsverteilungen der Parameterwerte des Modells (Block „Multiple Parametrierung des physikalischen Modells“) werden die vorhandenen n Messungen (d.h. die Mehrzahl von Messdatensätzen) in q Teile (Gruppen von Messdatensätzen) aufgeteilt. Für jeder dieser Datensatzteile wird eine Ermittlung der Parameter des Modells durchgeführt, sodass der Fehler zwischen Ausgangsdaten des physikalischen Modells und den Ausgangs-Messdaten der Gruppe von Messdatensätzen minimiert wird. Die Parameteroptimierungen ergeben q/n Parametersätze $S_{1,\ldots,q/n}$. Jeder Modell-Parameterwertesatz enthält in dem Beispiel m Modell-Parameterwerte $P_{1,\ldots,m}$. Ausgehend von den so identifizierten Parameterwerten, wird für jeden Parameter die Modell-Parameterwertverteilungen identifiziert. Für jeden Parameter, mit dem ein abnormaler Zustand erzeugt werden soll, kann die Verteilung an eine vorgegebene Wahrscheinlichkeitsverteilung, in Fig. 1d

eine Normalverteilung, gefittet werden. Diese Normalverteilung wird für die nachfolgend vorgestellte Erzeugung von abnormalen Zuständen verwendet.

Zusätzlich werden Parameterwertverteilungen des Normalzustands verwendet (Block „Identifikation der Parameterverteilung“), aus denen Modellparameterwerte für die Generierung der synthetischer Normalzustandsdaten gezogen werden. Die Parameterwerte können entweder direkt in eine Wahrscheinlichkeitsverteilung überführt werden oder die Parameterwerte können an verschiedene Wahrscheinlichkeitsverteilungen wie Normalverteilungen, multivariate Normalverteilungen, Chi-Quadrat-Verteilungen, Betaverteilungen, Dreiecksverteilungen usw. gefittet werden. In Fig. 1d wird dargestellt, wie die Parameterverteilung in einzelne Normalverteilungen (engl. Single Gaussian Distribution, SDL) und Mehrdimensionale Normalverteilungen (engl. Multivariate Gaussian Distribution, MDL) gefittet werden.

Aus diesen Wahrscheinlichkeitsverteilungen werden anschließend Modell-Parameterwerte gezogen (Block „Statistische Ziehung“). Mit diesen Werten wird das Modell parametriert. Aus den Eingangsdatenverteilungen werden optional die Eingangsdatenwerte gezogen. In anderen Worten können für die erste Mehrzahl von Simulationen des physikalischen Modells ferner basierend auf einer statistischen Verteilung der Eingangs-Messdaten ein oder mehrere Eingangs-Daten ausgewählt werden. Das Modell wird mit den gezogenen Parameterwerten und Eingangsdatenwerten simuliert. Dadurch entsteht ein synthetischen Datensatz (der ersten Mehrzahl von Trainingsdatensätzen) mit (optionalen) Eingangsdaten und Ausgangsdaten im Normalzustand. Dieser Vorgang kann so oft wiederholt werden, bis eine gewünschte Anzahl an synthetischen Normalzustandsdaten (der ersten Mehrzahl von Trainingsdatensätzen) erreicht ist.

Das vorgeschlagene Konzept wird ferner zur Erzeugung von abnormalen Zuständen, d.h. etwa Fehler-, Vor-Fehler-zuständen oder anderen abnormalen Zustände genutzt, d.h. zur Erzeugung der zweiten Mehrzahl von Trainingsdaten. Wie aus dieser Abgrenzung ersichtlich ist, bilden die erste Mehrzahl von Trainingsdatensätzen einen Normalzustand des technischen Bauteils ab und bilden die zweite Mehrzahl von Trainingsdatensätzen einen oder mehrere abnormale Zustände, wie etwa einen Beobachtungszustand, einen Vor-Fehlerzustand oder einen Fehlerzustand des technischen Bauteils ab. Die Erzeugung von Fehlerzuständen basiert auf der Manipulation von Parameterwerten des physikalischen Modells. Dafür können Parameter des Modells identifiziert werden, mit denen potenziell Fehler-, Vor-Fehler-zustände

oder andere abnormale Zustände abgebildet werden können. Die Werte der ausgewählten Modell-Parameter werden unter Berücksichtigung von Wahrscheinlichkeitsverteilungen bestimmt. Die Wahrscheinlichkeitsverteilungen für die Modell-Parameterwerte im potenziell Fehler-, Vor-Fehler-zustand oder, genereller, abnormalem Zustand können häufig nicht aus der Mehrzahl von Messdatensätzen identifiziert werden, da Messungen von abnormalen Zuständen häufig nicht in ausreichend großer Anzahl vorliegen. Stattdessen wird eine Wahrscheinlichkeitsverteilung in Relation zu der Verteilung der Modell-Parameterwerte des Normalzustands eingeführt, diese wird wie zuvor beschrieben bestimmt.

Das Verfahren umfasst das Durchführen 150 der zweiten Mehrzahl von Simulationen des physikalischen Modells, um die zweite Mehrzahl von Trainingsdatensätzen zu generieren. Dabei werden, wie in der ersten Mehrzahl von Simulationen, basierend auf der statistischen Verteilung der ermittelten Modell-Parameterwerte (die jeweils auf eine vorgegebene Wahrscheinlichkeitsverteilung gefittet sein können, wie etwa Normalverteilungen, multivariate Normalverteilungen, Chi-Quadrat-Verteilungen, Betaverteilungen, Dreiecksverteilungen) ein oder mehrere Modell-Parameterwerte für die jeweilige Simulation ausgewählt, jedoch wird für jede Simulation zumindest ein Modell-Parameterwert außerhalb des Hauptbereichs der statistischen Verteilung (etwa gemäß einer vorgegebenen Wahrscheinlichkeitsverteilung, falls die statistische Verteilung an eine vorgegebene Wahrscheinlichkeitsverteilung gefittet wurde) der ermittelten Modell-Parameterwerte ausgewählt. Dies steht im Gegensatz zu der ersten Mehrzahl von Simulationen, wo alle Modell-Parameterwerte entsprechend der statistischen Verteilung der jeweiligen ermittelten Modell-Parameterwertes ausgewählt werden. Beispielsweise können für die erste Mehrzahl von Simulationen die ein oder mehreren Modell-Parameterwerte innerhalb des Hauptbereichs der statistischen Verteilung der ermittelten Modell-Parameterwerte ausgewählt werden. Dabei deckt der Hauptbereich der statistischen Verteilung zumindest 90 % (oder zumindest 95 %, oder zumindest 98 %) der jeweiligen ermittelten Modell-Parameterwerte ab.

Ist die statistische Verteilung der Modell-Parameterwerte beispielsweise auf eine Normalverteilung gefittet, wie in Fig. 1d, so kann der Hauptbereich der statistischen Verteilung auch im Rahmen von Standardabweichungen angegeben werden. Beispielsweise kann für jede Simulation der zweiten Mehrzahl von Simulationen zumindest ein Modell-Parameterwert basierend auf einer vorgegebenen Mindestabweichung von einem Erwartungswert einer Normalverteilung der Modell-Parameterwerte ausgewählt wird. Dabei kann die vorgegebene

Mindestabweichung zumindest 2,5 (oder zumindest 5) Standardabweichungen betragen. Bei anderen vorgegebenen Wahrscheinlichkeitsverteilungen können ähnliche Berechnungsgrundlagen ausgewählt werden und beispielsweise die vorgegebene Mindestabweichung von einem zentralen Moment erster Ordnung (welche dem Erwartungswert im Fall der Normalverteilung entspricht) aus berechnet werden.

In Fig. 1e sind drei exemplarische Wahrscheinlichkeitsverteilungen für drei Intensitäten von abnormalen Zuständen dargestellt. Fig. 1e zeigt ein Diagramm einer Wahrscheinlichkeitsverteilung und einer basierend auf der Wahrscheinlichkeitsverteilung ausgeführten Auswahl eines Modell-Parameterwerts. In Fig. 1e werden die Werte des Modell-Parameters in Bezug auf den Mittelwert der Verteilung des zugehörigen Parameters bestimmt. Eine Parametrierung des Modells mit Parameterwerten außerhalb der eingeführten Normalzustandsverteilung (etwa außerhalb von einem oder zwei Standardabweichungen σ um den Erwartungswert) führt zu einer Simulation eines abnormalen Zustands. Der Startpunkt der eingeführten Wahrscheinlichkeitsverteilung wird *SP* bezeichnet, der Endpunkt *EP*. Über den Start- und Endpunkt kann die Intensität der Abnormalität (etwa des Fehlers) bei der Simulation eingestellt werden. Neben der dargestellten gleichverteilten Verteilung können auch andere Verteilungen angenommen werden. Entsprechen müssen dann andere Kenngrößen als *SP* und *EP* dieser Verteilungen festgelegt werden.

Zur Erzeugung synthetischer Daten von Fehler-, Vor-Fehlerzuständen oder anderer abnormaler Zustände werden alle Modell-Parameterwerte aus der jeweiligen Wahrscheinlichkeitsverteilung gezogen, mit Ausnahme des Modell-Parameterwertes, der für die Simulation des abnormalen Zustands verwendet wird. Gerade dieser Modell-Parameterwert wird aus der eingeführten Verteilung für die Erzeugung abnormaler Zustände bestimmt. In anderen Worten kann für jede Simulation der zweiten Mehrzahl von Simulationen ein Modell-Parameterwert außerhalb des Hauptbereichs der statistischen Verteilung der ermittelten Modell-Parameterwerte und andere Modell-Parameterwerte, sofern vorhanden, basierend auf (und insbesondere entsprechend) der statistischen Verteilung der ermittelten Modell-Parameterwerte ausgewählt werden. Weist das physikalische Modell genau einen Modell-Parameter auf, so wird folglich kein Parameter entsprechend der statistischen Verteilung der ermittelten Modell-Parameterwerte ausgewählt. In manchen Fällen können mehrere Modell-Parameterwerte gleichzeitig außerhalb des Hauptbereichs gewählt werden. Beispielsweise kann für zumindest eine Simulation der zweiten Mehrzahl von Simulationen zumindest zwei Modell-Parameterwerte

außerhalb des Hauptbereichs der statistischen Verteilung der jeweiligen Modell-Parameterwerteausgewählt werden. Dabei können die zumindest zwei Modell-Parameterwerte basierend auf einem vorbekannten Zusammenhang zwischen den zwei Modell-Parametern (und damit auch Modell-Parameterwerten) ausgewählt werden. Dieses Konzept kann beispielsweise angewandt werden, wenn ein solcher Zusammenhang bekannt ist (etwa, weil die beiden Modell-Parameter(werte) linear oder nicht-linear zusammenhängen).

In manchen Beispielen kann ein geeigneter Wert für jeden Parameter anhand vorhandener Messungen abnormaler Zustände festgelegt werden. Diese Werte können durch einen Algorithmus oder händisch bestimmt werden. Ein solcher Algorithmus sieht vor, die Werte für die Kenngrößen der Verteilungen so zu wählen, dass die simulierten abnormalen Zustände möglichst gut hinsichtlich bestimmter Kriterien im Vergleich zu den vorhandenen Messdaten abnormaler Zustände werden. Dabei ist nicht zwangsläufig das Kriterium des geringsten Fehlers zutreffend, da, insbesondere bei geringer Anzahl an Abnormalmessdaten, nicht gegeben ist, dass die vorhandenen Abnormalmessdaten die Grundgesamtheit ausreichend abbilden. Daher können synthetische Daten, auch wenn Sie keine „perfekte“ Übereinstimmung mit den vorhandenen Abnormalmessdaten haben, insgesamt zu einer besseren Leistung des Maschinenlern-Modells führen, als wenn die synthetischen Abnormalzustandsdaten die vorhandenen Abnormalzustandsmessdaten perfekt abbilden.

Das Modell wird mit den ausgewählten Parameterwerten parametrisiert. Die (optionalen) Eingangs-Daten werden aus den Eingangs-Datenverteilung ausgewählt und dem Modell zugeführt. In anderen Worten kann in manchen Beispielen für die zweite Mehrzahl von Simulationen des physikalischen Modells ferner basierend auf einer statistischen Verteilung der Eingangs-Messdaten ein oder mehrere Eingangs-Daten ausgewählt werden (entsprechend der Auswahl für die erste Mehrzahl von Simulationen). Anschließend kann das Modell simuliert werden. Dieser Vorgang kann so oft wiederholt werden, wie es für die Anwendung erforderlich ist, d.h. bis die Anzahl der zweiten Mehrzahl von Trainingsdaten ausreichend groß ist.

Das vorliegende Konzept bezieht sich auf das Erzeugen von Trainingsdaten zum Training eines Maschinenlern-Modells. Dabei handelt es sich bei den Trainingsdaten um Daten, die während des Trainings des Maschinenlern-Modells beispielsweise an einem Eingang oder einem Ausgang des Maschinenlern-Modells angelegt werden können, ggf. in verarbeiteter

Form. Weitere Details zu den Eigenschaften der Trainingsdaten werden im Zusammenhang mit den Fign. 2a bis 2g erläutert.

Das vorgeschlagene Konzept kann auf eine Vielzahl von verschiedenen technischen Bauteilen angewandt werden, soweit sich das entsprechende technische Bauteil ausreichend genau durch ein physikalisches Modell modellieren lässt. Beispielsweise kann das technische Bauteil eine Komponente einer Maschine oder einer technischen Anlage sein, etwa einer Maschine oder technischen Anlage der Energiewirtschaft. Insbesondere kann das technische Bauteil ein elektrotechnisches Bauteil sein, etwa eines von einem Transformator, einem Laststufenschalter, einem Leistungsschalter, einem Trennschalter, einem Lasttrennschalter, einer Schaltanlage, einem Kabel, einer Muffe, einer Freileitung und einer Hochspannungsdurchführung.

Für die Anwendung der modellbasierten Datenvermehrung zur Erstellung von Diagnosesystemen werden Normalzustandsdaten, ein Modell, das Zusammenhänge des zu diagnostizierenden Betriebsmittels abbildet, ein Algorithmus zur Ermittlung von Modell-Parameterwerten dieses Modells und optional Daten abnormaler Zustände verwendet. Das Modell, das Zusammenhänge des zu diagnostizierenden Betriebsmittels abbildet, kann entweder aus der Literatur entnommen werden oder es kann gezielt ein Modell für die jeweilige Diagnoseaufgabe gebildet werden.

Im Folgenden werden mehrere technische Bauteile nebst der für sie relevanten physikalischen Modelle und Modell-Parameter vorgestellt.

Die vorgestellte modellbasierte Datenvermehrung kann beispielsweise bei der Erstellung von Diagnosesystemen für diverse Betriebsmittel der Nieder-, Mittel-, Hoch- und Höchstspannungsebene eingesetzt werden, um dort den Erfolgsgrad von ML-Diagnosesystemen zu verbessern. Diese Betriebsmittel haben gemein, dass sie geringe Fehlerraten aufweisen, sodass nur, falls überhaupt, geringe Daten zu abnormalen Zuständen vorliegen.

In einem ersten Beispiel ist das technische Bauteil ein Transformator. Das Modell, das im Folgenden verwendet wird, ist der Literatur entnommen und modifiziert. Ein Transformator schwingt hauptsächlich aufgrund von zwei Effekten: Magnetostriktion und Lorentz-Kräfte. Die Magnetostriktion ist die Ursache für die Schwingung des Transformatorkerns in

Kombination mit den magnetischen Kräften. Die 100 Hz-Schwingungskomponente des Kerns ist proportional zum Quadrat der am Transformator anliegenden Spannung. Die Lorentz-Kräfte bringen die Wicklungen zum Schwingen. Die 100-Hz-Schwingungskomponente ist proportional zum Stromquadrat. Diese Beziehungen werden in dem Ausgangsmodell verwendet, das in der Formel (1) vorgestellt wird (entnommen aus Garcia et al: „Transformer Tank Vibration Modeling as a Method of Detecting Winding Deformations-Part I: Theoretical Foundation"). A_{100hz} gibt die Schwingungsamplitude der 100-Hz-Komponente an, i den effektiven mittleren Strom, u die effektive mittlere Spannung. α und β sind Koeffizienten zur Berücksichtigung der Schwingungsdämpfung entlang des Ausbreitungsweges und als Proportionalitätsfaktoren, und damit beispielsweise Modell-Parameter des physikalischen Modells.

$$A_{100hz} = \alpha * i^2 + \beta * u^2 \qquad (1)$$

Transformatoren für die Primär- und Sekundärverteilung werden in der Regel dreiphasig ausgelegt und sind nicht immer symmetrisch belastet. Daher wird das physikalische Modell um eine individuelle Betrachtung der Phase 1, 2 und 3 in Formel (2) erweitert.

$$\begin{aligned} A_{100hz} = {} & \alpha_1 * i_1^2 + \alpha_2 * i_2^2 + \alpha_3 * i_3^2 \\ & + \beta_1 * u_1^2 + \beta_2 * u_2^2 + \beta_3 \qquad (2) \\ & * {u_3}^2 \end{aligned}$$

Der Zusammenhang zwischen Schwingung und dem Quadrat von Strom und Spannung ist jedoch nur annähernd linear. Daher wird eine nichtlineare und streng monotone Funktion eingeführt, um die nichtlinearen Komponenten zu berücksichtigen. Formel 3 stellt das in diesem Beispiel verwendete physikalische Modell für Transformatorschwingungen dar. $\vec{b}$ ist der Parametervektor und $\vec{x}$ der Eingangsvektor.

$$\begin{aligned} A_{100hz} = {} & \lambda(\alpha_1 * i_1^2 + \alpha_2 * i_2^2 + \alpha_3 * i_3^2 \\ & + \beta_1 * u_1^2 + \beta_2 * u_2^2 + \beta_3 \qquad (3) \\ & * {u_3}^2) = \lambda(\vec{b} \cdot \vec{x}) \end{aligned}$$

Für dieses Modell sind die Modell-Parameter $\alpha_1, \alpha_2, \alpha_3, \beta_1, \beta_2, \beta_3$ und die nichtlineare Funktion λ durch einen Parametrisierungsalgorithmus ermittelt worden. Das Modell besteht aus einem linearen Teil $\vec{b} - \cdot \vec{x}$ und einem nichtlinearen Teil λ. Daher wird die Parametrierung in zwei Stufen durchgeführt, eine Stufe für die Optimierung des nichtlinearen Teils und eine Stufe für die Optimierung des linearen Teils. Die beiden Stufen wurden abwechselnd

durchgeführt, um das Ergebnis der Parametrierung kontinuierlich zu verbessern, bis ein Abbruchkriterium erreicht ist.

Der Vorgang der Parametrierung ist in Fig. 1f dargestellt. Fig. 1f zeigt ein Diagramm eines Beispiels eines Ermittelns von Modell-Parameterwerten für ein physikalisches Modell eines Transformators. Die Funktion λ wird mit der Identitätsfunktion initialisiert. In der ersten Stufe werden die Parameter des physikalischen Modells $\vec{b}$ durch Lösen von $\lambda^{-1}(A) = \vec{b} - \cdot \vec{x}$ mit einer Methode der kleinsten Quadrate bestimmt. In der zweiten Stufe wird die nichtlineare Funktion λ mit einer isotonischen Regression identifiziert. Die isotonische Regression bildet zwischen einer abhängigen und einer unabhängigen Variable ab. In diesem Beispiel werden durch die Verwendung einer isotonischen Regression keine Annahmen durch eine Vorparametrisierung, Funktionsform oder Grad benötigt.

Zur Anwendung der modellbasierten Datenvermehrung unter Verwendung des Transformator-Vibrationsmodells, werden die Verteilungen der Modell-Parameterwerte für die Modell-Parameter $\alpha_1, \alpha_2, \alpha_3, \beta_1, \beta_2, \beta_3$ ermittelt. Die nichtlineare Funktion λ wird nur einmal an alle Messungen angepasst und für die Generierung der synthetischen Daten nicht variiert. Wendet man diese Methode auf die Diagnoseaufgabe des Transformatorfehlers an, können Fehler-, Vor-Fehler-zustände oder andere abnormale Zustände mit den Modell-Parametern $\alpha_1, \alpha_2, \alpha_3, \beta_1, \beta_2, \beta_3$ sequenziell simuliert werden. Der Startpunkt der Verteilung für abnormale Zustände wird beispielsweise $SP = \mu_{Normalzustand} + 5\sigma$ und der Endpunkt auf $EP = \mu_{Normalzustand} + 25\sigma$ gesetzt, wobei $\mu_{Normalzustand}$ in der Normalverteilung dem Erwartungswert entspricht.

Ein zweites Beispiel befasst sich mit der Berechnung der Heißpunktemperatur eines Transformators (engl. hot spot temperature) in Abhängigkeit von Umgebungstemperatur, Last und Transformatorkenngrößen nach DIN IEC 60076-7 oder Susa et al: „A Simple Model for Calculating Transformer Hot-Spot Temperature". Eine Erhöhte Temperatur lässt Rückschlüsse auf Zustand des Transformators zu. Diese Modelle können für die modellbasierte Datenvermehrung (auch engl. Model-based Data Augmentation, MDA) eingesetzt werden.

Nach DIN IEC 60076-7 berechnet sich die Heißpunkttemperatur aus der Summe der Umgebungstemperatur θ_{amb}, der Übertemperatur der obersten Ölschicht $\Delta\theta_{TOT}$, und der Temperaturdifferenz zwischen Heißpunkt und oberster Ölschicht $\Delta\theta_{HST}$. Das Modell kann nach DIN

IEC 60076-7 Abschnitt 8.2.3 mit Differentialgleichungen in einem Blockdiagramm dargestellt werden. Es werden drei Stränge betrachtet, die die jeweiligen Eingangsgrößen (etwa Eingangsdaten oder Eingangs-Messdaten) K, Kund θ_{amb} aufweisen, K beschreibt dabei einen zeitveränderlichen Lastfaktor und θ_{amb} die Umgebungstemperatur. Im ersten Strang wird $\Delta\theta_{HST}$ aus $\frac{k_{21}}{1+k_{22}\cdot\tau_W\cdot s} - \frac{k_{21-1}}{1+\frac{\tau_0}{k_{22}}\cdot s}$ berechnet, was wiederum aus $\Delta\theta_{\mathrm{HST,r}} \cdot K^y$ hervorgeht. $s$ist die Laplace-Variable. Im zweiten Strang wird $\frac{1}{1+k_{11}\cdot\tau_0\cdot s}$ berechnet, was wiederum aus $\Delta\theta_{TOT,r} \cdot (\frac{1+R\cdot K^2}{1+R})$ hervorgeht. Im dritten Strang wird $\frac{1}{1+k_{11}\cdot\tau_0\cdot s}$ mit θ_{amb} als Eingangsgröße berechnet. Durch Addition des zweiten und dritten Strangs wird θ_{TOT} berechnet, durch Addition aller drei Stränge θ_{HST}. Die Parameter dabei sind die zeitabhängige Ölübertemperatur $\Delta\theta_{TOT}(t)$, der Wicklungslastfaktor $K_{Wicklung}$, der Wicklungsexponent y, die Bemessungsölübertemperatur $\Delta\theta_{HST,r}$. Die Parameter k_{21}, k_{11} und k_{22} sind von dem Transformator und Kühlungsart abhängig, Zeitkonstanten der Wicklungen bzw. des Öls τ_W und τ_0, θ_{TOT} Temperatur des Öls oben im Transformatortank, θ_{HST} Heißpunkttemperatur des Transformators, θ_{amb} Umgebungstemperatur. Größe $\boldsymbol{R}$ stellt das Verlustverhältnis zwischen Kurzschluss- und Leerlaufverlusten dar. Beispielsweise können Parameter wie Wicklungsexponenten, Bemessungsölübertemperatur oder die Parameter k_{21}, k_{11} und k_{22} nicht immer eindeutig identifiziert werden oder unterliegen Schwankungen. Daher können diese Parameter mit einem Fitting-algorithmus durch die Messdaten angepasst werden und anschließend zur Simulation von Normalzustandsdaten oder auch Daten abnormaler Zustände verwendet werden. So könnten synthetische Temperaturdaten in unterschiedlichen Betriebszuständen erstellt werden. In anderen Worten können die Parameter k_{21}, k_{11} und k_{22} als auszuwählende Modell-Parameter dieses Modells verwendet werden (d.h. als Modell-Parameter, deren Werte in der zweiten Mehrzahl von Simulationen außerhalb des Hauptbereichs der statistischen Verteilung ausgewählt werden können), und die zuvor genannten Eingangsgrößen als Eingangsdaten/Eingangs-Messdaten.

Ein drittes Beispiel befasst sich mit einem physikalischen Modell eines Gebäudes. In diesem Fall kann das Gebäude, oder ein Raum des Gebäudes, als technisches Bauteil aufgefasst werden. Das folgende physikalisches Modell nach Schenk: „Thermische Bemessung von Netzstationen“ ist ein thermisches Gebäudemodell eines Gebäudes mit Wärmequelle und Verbindung zur Umgebung in Form eines Wärmenetzes. Folgende Größen werden in dem Modell berücksichtigt: P_{Tr}: Wärmeleistung Wärmequelle, C_{Tr}:thermische Kapazität der

Wärmequelle, C_{St}:Thermische Kapazität der Station, R_{K2}: Konvektion Raumluft → Innenwand, R_{K1}: Konvektion Wärmequelle → Kabinenluft, R_V: Natürliche oder forcierte Konvektion durch Belüftung, R_{S1}: Strahlung Wärmequelle → Rauminnenwand, R_{K3}: Konvektion Außenwand → Umgebungsluft, R_{S2}: Strahlung Außenwand → Umgebung, R_{WL}: Wärmeleitung Innenwandseite → Außenwandseite, und θ_{amb}:Umgebungstemperatur

In diesem Modell nach können diverse Parameter wie beispielsweise die Wärmeleitung innerhalb von Wänden, Parameter bei der Konvektion von Wänden zu Luft nicht genau aus Datenblättern o.Ä. bestimmt werden oder unterliegen Schwankungen. Diese Parameter können als Modell-Parameterwerte des physikalischen Modells mit einem Fitting des Modells an Messdaten bestimmt werden. Durch eine Simulation mit diesen Modell-Parameterwerten können abnormale Zustände wie zu starke Belüftung oder Auskühlung durch Schäden an Wänden, der Belüftungseinrichtung oder auch an der Wärmequelle identifiziert werden.

Ein viertes Beispiel sind Belüftungsmodelle, welche eine Abbildung natürlicher oder forcierter Belüftung eines Gebäudes/Raums durch physikalische Modelle in Abhängigkeit von Belüftungskenngrößen bereitstellt. Diese Modelle bilden Größen wie Gebäudetemperatur, Luftdruck im Gebäudeinneren und Druck außen vom Gebäude und Außentemperatur ab. Dadurch könnten Diagnosesysteme geschaffen werden, die Defekte am Belüftungsmechanismus aufdecken oder auch offenstehende Fenster etc. identifizieren. Diese Modelle können für die modellbasierte Datenvermehrung eingesetzt werden.

Für eine natürliche Belüftung kann beispielsweise ein Modell nach Degefa et al.: „Dynamic Thermal Modeling of MV/LV Prefabricated Substations“ verwendet werden.

$$\dot{V} = f_i * A_{vent} * \sqrt{2 * \left|(H_0 - H_i) * g * \frac{\theta_{cabin,i} - \theta_{amb}}{\theta_{amb}}\right|}$$

$\dot{V}$ ist der resultierende Volumenstrom durch bspw. ein Fenster oder Gitter. A_{vent} ist die Fläche des Gitters. f_i ist eine Funktion, die den Volumenstrom durch die Gitter skaliert, H_i die treibende Druckhöhe und $\theta_{cabin,i}$ die Kabinentemperatur. Die Funktion f_i kann als Modell-Parameterwert durch einen Fitting-Algorithmus bestimmt werden und für die Simulation von abnormalen Zuständen angepasst werden. Die Parameter dieser Funktion können beispielsweise für die Simulation von Normal- und abnormalen Zuständen angepasst und verwendet werden. Damit können dann beispielsweise verstopfte Lüftungsgitter etc. simuliert werden

und über die modellbasiert Datenvermehrung in Maschinenlern-Modelle eingebunden werden.

In Rusek et al.: „Monitoring and Diagnosis of Pantograph Disconnectors“ wird ein blockbasiertes Modell vorgestellt, das einen Pantographentrennschalter repräsentiert. Die Blöcke bilden bewegliche Bauteilen, Antrieb und Bewegungsmechanismus ab. Dieses Modell weist diverse Modell-Parameter wie Versorgungsspannung des DC-Motors, Widerstandswerte von Kabeln oder eines Vorwiderstands, oder auch Feder- und Dämpfungskonstanten der durch Federn und Dämpfern repräsentierten Pantographenarme auf. Im Modell können diverse Größen abgegriffen werden, die auch messtechnisch an einem Pantographentrennschalter (als Eingangs- oder Ausgangs-Messdaten) erfasst werden können wie beispielsweise Drehzahl des DC-Motors, benötigter Strom des DC-Motors etc. Die Versorgungsspannung ist zwischen verschiedenen Schalthandlungen nicht, wie in dem Modell angenommen, konstant, die Dämpfungs- und Federkonstanten, Funktionen wie die Motormagnetisierungsfunktion, Reibungskonstanten etc. können häufig nicht vollständig anhand technischer Datenblätter bestimmt werden. Diese können als Modell-Parameterwerte mit einem Fitting-Algorithmus bestimmt werden und anschließend für die Normalzustandssimulation aus den identifizierten Parameterwertverteilungen gezogen werden. Diese Parameter können auch eingesetzt werden, um synthetische Daten abnormaler Zustände mit der modellbasierten Datenvermehrung zu generieren. Damit können beispielsweise weiche Scherenarme, verringerte Versorgungsspannung, erhöhte Reibung etc. simuliert werden.

Ein weiteres Beispiel bezieht sich auf ein Wärmenetz eines 3-phasigen Kabels nach IEC 60287. Dabei sind mögliche Parameter des Modells die Hauptverluste des Kabels W_c also die Verluste, die durch den Stromfluss durch einen Widerstand entstehen (I^2R-Verluste), Einflüsse des Skin-Effekt W_s, sowie die dielektrischen Verluste W_d, die für Spannungsebenen kleiner 127 kV nicht berücksichtigt werden müssen. Weitere Parameter sind beispielsweise T_1 thermischer Widerstand pro Kabel zwischen Leiter und Schirm, T_2 thermischer Widerstand zwischen Schirm und Armierung, T_3 thermischer Widerstand des Außenmantels, T_4thermischer Widerstand der Umgebung. Die thermischen Widerstände können durch interne oder externe Einflüsse variieren, ebenso können Parameter, die zur Berechnung von W_d, W_s und W_a benötigt werden, variieren. Diese können als Modell-Parameterwerte über einen Fitting-Algorithmus bestimmt werden. Damit können über die modellbasierte Datenvermehrung synthetische Normalzustandsdaten- und Daten abnormaler Zustände generiert werden. Die

Modell-Parameterwerte können in der Simulation von abnormalen Zuständen eingesetzt werden, um lokale Widerstandserhöhungen, oder beschädigte Ummantelung zu simulieren. Diese haben einen Einfluss auf die Temperatur des Kabels.

Ein weiteres Beispiel bezieht sich auf Freileitungen. Bei Freileitungen ist ebenfalls die Temperatur von Bedeutung, da mögliche Heißpunkte auf eine schlechte elektrische Leitfähigkeit hindeuten. Die Cigre Working Group B2.43 hat 2014 im "Guide for Thermal Rating Calculations of Overhead Lines" die Wärmebilanzgleichung vereinfacht mit

$$P_J + P_S = P_C + P_r$$

dargestellt. P_J ist der Beitrag von joulschen Verlusten, P_s der Wärmeeintrag durch Sonneneinstrahlung, P_C konvektive Kühlung und P_r radiative Kühlung. P_J kann mit

$$P_J = I^2 * R_{DC}$$

berechnet werden. I ist dabei der Strom, der durch die Freileitung fließt. R_{DC} ist der DC-Widerstand der Freileitung pro Längeneinheit. Dieser hängt von dem spezifischen Widerstand des Materials ab. P_S kann mit

$$P_S = \alpha_s * I_T * D$$

berechnet werden. α_s beschreibt dabei den Absorptionskoeffizienten der Oberfläche der Freileitung, I_T die Intensität der Globalstrahlung und D den Außendurchmesser der Freileitung. Die Cigre Working Group stellt noch eine weitere Möglichkeit dar, wie P_s berechnet werden kann.

P_C wird mit

$$P_C = \pi * \lambda_f * (T_s - T_a) * Nu$$

berechnet. λ_f ist die Wärmeleitfähigkeit von Luft bei T_f. T_f ist die Temperatur der Luftschicht, die in Kontakt mit der Freileitungsoberfläche ist. T_s und T_a sind die Temperaturen des Leiters und der Luft.

P_r wird mit

$$P_r = \pi * D * \sigma_B * F_{c-g} * \epsilon_s * \left[(T_s + 273)^4 - \left(T_g + 273\right)^4\right] + \pi * D * \sigma_B * F_{c-sky} * \epsilon_s * [(T_s + 273)^4 - \left(T_{sky} + 273\right)^4]$$

berechnet. D ist der Außendurchmesser des Leiters, σ_B die Stefan-Boltzmann Konstante, ϵ_s der Emissionsgrad der Oberfläche des Leiters, T_s die Temperatur des Leiters, T_g die Temperatur des Bodens unter dem Leiter, T_{sky} die Temperatur des Himmels über dem Leiter, F_{c-g} der Teil der vom Leiter abgestrahlten Energie an den Boden und die Umgebung und F_{c-sky} der Teil der vom Leiter abgestrahlten Energie in den Himmel.

Für dieses Modell kann die modellbasierte Datenvermehrung angewendet werden, indem Parameter wie R_{DC}, oder die Anteile der abgestrahlten Energie F_{c-g} und F_{c-sky} als Modell-Parameterwerte mit einem Algorithmus mehrfach gefittet werden. Über die modellbasierte Datenvermehrung können dann synthetische Normalzustandsdaten erzeugt werden. Abnormale Zustände können durch eine Erhöhung von R_{DC} generiert werden.

Die Schnittstelle 12 kann beispielsweise einem oder mehreren Eingängen und/oder einem oder mehreren Ausgängen zum Empfangen und/oder Übertragen von Informationen entsprechen, etwa in digitalen Bitwerten, basierend auf einem Code, innerhalb eines Moduls, zwischen Modulen, oder zwischen Modulen verschiedener Entitäten.

Beispielsweise können die ein oder mehreren Prozessoren 14 einem beliebigen Controller oder Prozessor oder einer programmierbaren Hardwarekomponente entsprechen. Beispielsweise kann die Funktionalität der ein oder mehreren Prozessoren 14 auch als Software realisiert sein, die für eine entsprechende Hardwarekomponente programmiert ist. Insofern können die ein oder mehreren Prozessoren 14 als programmierbare Hardware mit entsprechend angepasster Software implementiert sein. Dabei können beliebige Prozessoren, wie Digitale Signalprozessoren (DSPs) zum Einsatz kommen. Ausführungsbeispiele sind dabei nicht auf einen bestimmten Typ von Prozessor eingeschränkt. Es sind beliebige Prozessoren oder auch mehrere Prozessoren zur Implementierung denkbar.

Die ein oder mehreren Speichergeräte 16 können beispielsweise zumindest ein Element der Gruppe von computerlesbares Speichermedium, magnetisches Speichermedium, optisches Speichermedium, Festplatte, Flash-Speicher, Diskette, Zufallszugriffsspeicher (auch engl. Random Access Memory), Programmable Read Only Memory (PROM), Erasable Programmable Read Only Memory (EPROM), Electronically Erasable Programmable Read Only Memory (EEPROM), und Netzwerkspeicher umfassen.

Mehr Details und Aspekte der Datenvermehrung werden in Verbindung mit dem Konzept oder Beispielen genannt, die vorher oder nachher (etwa Fign. 2a bis 3b) beschrieben werden. Die Datenvermehrung, und damit auch das entsprechende Verfahren, die Vorrichtung und das Computerprogramm, kann ein oder mehrere zusätzliche optionale Merkmale umfassen, die

ein oder mehreren Aspekten des vorgeschlagenen Konzepts oder der beschriebenen Beispiele entsprechen, wie sie vorher oder nachher beschrieben wurden.

Einen zweiten Aspekt der vorliegenden Offenbarung stellt das Training eines Maschinenlern-Modells basierend auf den zuvor generierten Trainingsdaten dar.

Fig. 2a zeigt ein Flussdiagramm eines Beispiels eines computer-implementierten Verfahrens zum Trainieren eines Maschinenlern-Modells zur Vorhersage eines Zustands eines technischen Bauteils. Das Verfahren umfasst ein Erhalten 210 einer ersten Mehrzahl von Trainingsdatensätzen und einer zweiten Mehrzahl von Trainingsdatensätzen. Die erste Mehrzahl von Trainingsdatensätzen und die zweite Mehrzahl von Trainingsdatensätzen sind basierend auf dem Verfahren der Fign. 1a bis 1f generiert. In anderen Worten basieren die erste und zweite Mehrzahl von Trainingsdatensätzen auf einer modellbasierten Datenvermehrung. Die erste und zweite Mehrzahl von Trainingsdatensätzen stellen synthetisch generierte Trainingsdatensätze dar. Dabei bilden die erste Mehrzahl von Trainingsdatensätzen einen Normalzustand des technischen Bauteils ab. Die zweite Mehrzahl von Trainingsdatensätzen bildet einen oder mehrere abnormale Zustände des technischen Bauteils ab. Optional umfasst das Verfahren ferner ein Erhalten 220 einer Mehrzahl von Messdatensätzen über das technische Bauteil. Das Verfahren umfasst ferner ein Trainieren 230 des Maschinenlern-Modells basierend auf der ersten Mehrzahl von Trainingsdatensätzen und basierend auf der zweiten Mehrzahl von Trainingsdatensätzen, und optional, basierend auf der Mehrzahl von Messdatensätzen basiert. Das Verfahren kann ferner ein Bereitstellen oder Ausgeben des Maschinenlern-Modells umfassen, etwa über eine Schnittstelle oder über eine Speichereinrichtung.

Fig. 2b zeigt ein Blockdiagramm eines Beispiels einer entsprechenden computer-implementierten Vorrichtung zum Trainieren eines Maschinenlern-Modells zur Vorhersage eines Zustands eines technischen Bauteils. Die Vorrichtung 20 umfasst ein oder mehreren Prozessoren 24 und ein oder mehreren Speichereinrichtungen 26. Optional umfasst die Vorrichtung 20 ferner eine Schnittstelle 22. Die Vorrichtung 20 ist ausgebildet zum Durchführen zumindest des Verfahrens von Fig. 2a. Optional kann die Vorrichtung 20 ferner ausgebildet sein, um das Verfahren von Fig. 1a und/oder das Verfahren von Fig. 3a auszuführen. Dabei wird die Funktionalität der Vorrichtung 20 von den ein oder mehreren Prozessoren 24 der Vorrichtung bereitgestellt, unter Zuhilfenahme der optionalen Schnittstelle 22 (etwa zum Erhalten der Trainingsdatensätze und der Messdatensätze) und der ein oder mehreren Speichereinrichtungen

(etwa zum Speichern der Messdatensätze, der Trainingsdatensätze und des Maschinenlern-Modells).

Die folgende Beschreibung bezieht sich sowohl auf das Verfahren von Fig. 2a als auch auf ein entsprechendes Computerprogramm und die entsprechende Vorrichtung von Fig. 2b. Merkmale, die im Zusammenhang des Verfahrens eingeführt werden, können daher auch in die entsprechende Vorrichtung und das Computerprogramm übernommen werden (und umgekehrt).

Durch das Verfahren, die Vorrichtung und das Computerprogramm der Fign. 2a bis 2g werden die Trainingsdatensätze, die entsprechend der Lehre der Fign. 1a bis 1f generiert wurden, genutzt, um das Maschinenlern-Modell zu trainieren. Maschinelles Lernen bezieht sich, im Allgemeinen, auf Algorithmen und statistische Modelle, die Computersysteme verwenden können, um eine bestimmte Aufgabe ohne Verwendung expliziter Anweisungen auszuführen, durch Nutzung von Modellen und Inferenz. Beim maschinellen Lernen kann beispielsweise anstatt einer auf Regeln basierenden Transformation von Daten, eine Transformation von Daten verwendet werden, die aus einer Analyse von Verlaufs- und/oder Trainings-Daten hergeleitet werden kann. Beispielsweise kann der Inhalt von Bildern unter Verwendung eines Maschinenlern-Modells oder unter Verwendung eines Maschinenlern-Algorithmus analysiert werden. Damit das Maschinenlern-Modell den Inhalt eines Bildes analysieren kann, kann das Maschinenlern-Modell unter Verwendung von Trainingsbildern als Eingabe und Trainingsinhaltsinformation als Ausgabe trainiert werden. Durch Trainieren des Maschinenlern-Modells mit einer großen Anzahl von Trainingsbildern und zugeordneter Trainingsinhaltsinformation (z. B. Kennzeichnungen oder Anmerkungen) „lernt“ das Maschinenlern-Modell, den Inhalt der Bilder zu erkennen, sodass der Inhalt von Bildern, die in den Trainingsdaten nicht umfasst sind, unter Verwendung des Maschinenlern-Modells erkannt werden kann. Das gleiche Prinzip kann für andere Arten von Sensordaten, vorverarbeiteten Sensordaten oder aus Sensordaten extrahierten Informationenebenfalls verwendet werden: Durch Trainieren eines Maschinenlern-Modells unter Verwendung von Trainingssensordaten und einer erwünschten Ausgabe „lernt“ das Maschinenlern-Modell eine Umwandlung zwischen den Sensordaten und der Ausgabe, was verwendet werden kann, um eine Ausgabe basierend auf an das Maschinenlern-Modell bereitgestellten Sensordaten zu erzeugen.

Maschinenlern-Modelle werden unter Verwendung von Trainingseingabedaten trainiert. Die oben angeführten Beispiele verwenden ein Trainingsverfahren, das „Supervised Learning“ (Überwachtes Lernen) genannt wird. Beim Supervised Learning wird das Maschinenlern-Modell unter Verwendung einer Mehrzahl von Trainingsdatensätzen trainiert, wobei jeder Datensatz eine Mehrzahl von Eingabedatenwerten und eine Mehrzahl von erwünschten Ausgabewerten, d. h. jedem Trainingsdatensatz ist ein erwünschter Ausgabewert zugeordnet, umfassen kann. Durch Angeben sowohl von Trainingsdatensätzen als auch erwünschten Ausgabewerten „lernt“ das Maschinenlern-Modell, welcher Ausgabewert basierend auf einem Eingabeabtastwert, der ähnlich zu den während des Trainings bereitgestellten Abtastwerten ist, bereitzustellen ist. Supervised Learning kann auf einem Supervised Learning-Algorithmus basieren, beispielsweise auf einem Klassifizierungsalgorithmus. Klassifizierungsalgorithmen können verwendet werden, wenn die Ausgaben auf eine begrenzte Menge von Werten (kategorische Variablen) beschränkt sind, d. h. die Eingabe ist als einer aus dem begrenzten Satz von Werten klassifiziert.

Die durch das Verfahren, die Vorrichtung und das Computer-Programm generierten Trainingsdatensätze sind Trainingsdatensätze, die zu dem Training des Maschinenlern-Modells verwendet werden können. Dazu kann in manchen Fällen eine Vorverarbeitung der Trainingsdatensätze durchgeführt werden, etwa um Merkmalsvektoren für ein oder mehrere Eingabeschnittstellen des Maschinenlern-Modells zu generieren, oder um den erwünschten Ausgabewert aus dem jeweiligen Trainingsdatensatz zu extrahieren. Je nach Ausgestaltung des Maschinenlern-Modells können die Trainingsdatensätze unterschiedliche Bestandteile aufweisen. Da die Trainingsdatensätze, die im Zusammenhang mit den Fign. 1a bis 1f generiert werden, die entsprechenden Messdatensätze imitieren, können die Trainingsdatensätze ebenfalls ein oder mehrere Ausgabedaten (die den ein oder mehreren Mess-Ausgabedaten entsprechen können), und optional ein oder mehrere Eingabedaten (die den ein oder mehreren Eingabe-Messdaten entsprechen können) umfassen. Diese können in ihrer Ausgestaltung den jeweiligen Messdaten entsprechen. Dabei können die ein oder mehreren Ausgabedaten und die optionalen ein oder mehreren Eingabedaten in dem Training des Maschinenlern-Modells an den jeweiligen Eingängen des Maschinenlern-Modells bereitgestellt werden.

In einigen Beispielen wird das Maschinenlern-Modell mittels Supervised Learning trainiert, d.h. die (ersten und zweiten) Trainingsdatensätze werden zusammen mit entsprechenden erwarteten Ausgabenwerten genutzt, um das Maschinenlern-Modell zu trainieren. Dabei kann

das Maschinenlern-Modell beispielsweise als sogenannter Klassifikator trainiert werden, d.h. das Maschinenlern-Modell wird trainiert, um die Daten, die an den Eingängen des Maschinenlern-Modells angelegt werden, in eine von zumindest zwei verschiedenen Klassifizierungen zu klassifizieren. Beispielsweise kann das Maschinenlern-Modell als Klassifikator für den Zustand des technischen Bauteils trainiert werden, d.h. die Daten, die an den Eingängen des Maschinenlern-Modells angelegt werden, werden genutzt, um den Zustand des technischen Bauteils in eine von zwei oder mehreren Klassifizierungen zu klassifizieren. Dazu kann beispielsweise die Zugehörigkeit der Trainingsdatensätze zu der ersten oder zweiten Mehrzahl von Trainingsdatensätzen als erwartete Ausgabewerte genutzt werden, da die Zugehörigkeit eines Trainingsdatensatzes zu der ersten Mehrzahl von Trainingsdatensätzen ein Hinweis darauf ist, dass der Trainingsdatensatz einen Normalzustand des technischen Bauteils repräsentiert, während die Zugehörigkeit eines Trainingsdatensatzes zu der zweiten Mehrzahl von Trainingsdatensätzen ein Hinweis darauf ist, dass der Trainingsdatensatz einen abnormalen Zustand des technischen Bauteils repräsentiert. Folglich können die erste und zweite Mehrzahl von Trainingsdatensätzen als Eingabedaten und die Zugehörigkeit der Trainingsdatensätze zu einer der ersten und zweiten Mehrzahl von Trainingsdatensätzen als erwünschte Ausgabedaten für das Supervised Learning-basierte Training verwendet werden. Alternativ oder zusätzlich kann Wissen darüber, mit welchem Modell-Parameterwert (oder welcher Modell-Parameterwert außerhalb des Hauptbereichs der statistischen Verteilung ausgewählt wurde) ein Trainingsdatensatz der zweiten Mehrzahl von Trainingsdatensätzen entstanden ist, als Ausgabewert genutzt werden, da damit ein Rückschluss auf den Typ eines möglichen abnormalen Zustands gezogen werden kann.

Dabei kann das Maschinenlern-Modell beispielsweise darauf trainiert werden, eine Klassifikation zwischen einem Normalzustand und ein oder mehreren abnormalen Zuständen des technischen Bauteils zu treffen.

In einem einfachen Beispiel kann die Klassifikation beispielsweise zwischen den beiden Zuständen „Normalzustand“ und „Fehlerzustand“ erfolgen. Dafür kann das Maschinenlern-Modell trainiert werden, um basierend auf einen Datensatz mit Messdaten (die an die Eingänge des Maschinenlern-Modells angelegt werden) den Zustand des technischen Bauteils in eine der Klassifikationen Normalzustand und Fehlerzustand einzuteilen. Dabei kann der Fehlerzustand beispielsweise eine Form des „abnormalen Zustands“ sein.

In einem weiteren Beispiel kann ein zusätzlicher Zustand unterschieden werden. Beispielsweise kann das Maschinenlern-Modell trainiert werden, um basierend auf einen Datensatz mit Messdaten den Zustand des technischen Bauteils in eine der Klassifikationen Normalzustand, Vor-Fehlerzustand und Fehlerzustand einzuteilen. Dabei kann der Vor-Fehlerzustand ein Zustand sein, der zwischen dem Normalzustand und dem Fehlerzustand einzuordnen ist. Beispielsweise kann der Vor-Fehlerzustand ein Zustand sein, der nicht (unmittelbar) zu einem Fehler oder Ausfall des technischen Bauteils führt, aber der dennoch beobachtet werden sollte. Dabei kann der Vor-Fehlerzustand auch ein ungefährlicher Zustand sein. Der Vor-Fehlerzustand kann eine weitere Form des „abnormalen Zustands“ sein.

In einer weiteren Ausführungsform kann das Maschinenlern-Modell ferner genutzt werden, um eine Fehlertypisierung durchzuführen. Dazu kann das Maschinenlern-Modell trainiert werden, um zwischen dem Normalzustand und unterschiedlichen Fehlerzuständen zu unterschieden. Beispielsweise kann das Maschinenlern-Modell trainiert werden, um basierend auf einen Datensatz mit Messdaten einen Zustand des technischen Bauteils in zumindest eine der Klassifikationen Normalzustand, erster Fehlerzustand und zweiter Fehlerzustand einzuteilen. Auch Mischformen sind möglich. Beispielsweise kann das Maschinenlern-Modell trainiert werden, um basierend auf einen Datensatz mit Messdaten einen Zustand des technischen Bauteils in zumindest eine der Klassifikationen Normalzustand, ein oder mehrere unterschiedliche Vor-Fehlerzustände und ein oder mehrere Fehlerzustände einzuteilen.

Die synthetischen Trainingsdatensätzen können auf verschiedene Arten in die Erstellung und insbesondere das Training des Maschinenlern-Modells integriert werden.

Einerseits kann das Maschinenlern-Modell ausschließlich basierend auf den synthetischen Trainingsdatensätzen trainiert werden.

Alternativ kann das Maschinenlern-Modell basierend auf den synthetischen Trainingsdatensätzen und basierend auf der Mehrzahl von Messdatensätzen trainiert werden, wie im Folgenden ausgeführt wird.

Hierbei sind wiederum mehrere Alternativen möglich. Der erste Ansatz sieht vor, dass die vorhandenen Messdatensätze mit synthetischen Daten erweitert wird. Beispielsweise können die synthetischen Trainingsdatensätze (oder zumindest die zweite Mehrzahl von

Trainingsdatensätzen) mit den Messdatensätzen kombiniert werden, um das Maschinenlern-Modell zu trainieren. Dabei können die Messdatensätze entweder mit nur synthetischen Normalzustandsdaten (der ersten Mehrzahl von Trainingsdatensätzen) oder mit nur synthetischen Daten abnormaler Zustände (der zweiten Mehrzahl von Trainingsdatensätzen) oder mit synthetischen Normal- und Daten abnormaler Zustände erweitert werden. In anderen Worten können die Mehrzahl von Messdatensätzen um die erste und/oder zweite Mehrzahl von Trainingsdatensätzen erweitert werden und das Maschinenlern-Modell gemeinsam basierend auf der Mehrzahl von Messdatensätzen und der ersten und/oder zweiten Mehrzahl von Trainingsdatensätzen trainiert werden.

Die Fign. 2c und 2d zweigen zwei Beispiele einer Vermischung von Messtrainingsdaten und synthetischen Trainingsdaten. In Fig. 2c werden die Messdatensätze (Observationen) $n_{O,nz}$ des Normalzustands und $n_{O,fz}$ des abnormalen Zustands durch die modellbasierte Datenvermehrung um synthetische Daten $n_{DA,nz}$ des Normalzustands und $n_{DA,fz}$ des abnormalen Zustands ergänzt; die jeweiligen Datensätze $n_{O,nz}$ und $n_{DA,nz}$ sowie $n_{O,fz}$ und $n_{DA,fz}$ werden jeweils für das Training des Maschinlern-Modells kombiniert. Alternativ können, wie in Fig. 2d gezeigt wird, durch die modellbasierte Datenvermehrung ausschließlich synthetische Daten $n_{DA,fz}$ des abnormalen Zustands generiert werden, die mit den Messdatensätzen $n_{O,fz}$ des abnormalen Zustands für das Training des Maschinlern-Modells kombiniert werden.

Der zweite Ansatz sieht vor, dass mit synthetischen Daten der modellbasierten Datenvermehrung eine Quelldomäne erschaffen wird, mit der Maschinenlern-Modelle trainiert werden können. Die synthetischen Daten können durch die modellbasierte Datenvermehrung oder auch durch eine andere Art der Datenvermehrung erstellt werden. Die so trainierten Maschinlern-Modelle können anschließend mit Verfahren des sogenannten Transfer Learning (Transferlernen) auf die zur Verfügung stehenden Messungen transferiert werden. Beispielsweise kann das Maschinenlern-Modell in einem ersten Schritt basierend auf der ersten und zweiten Mehrzahl von Trainingsdatensätzen trainiert werden. Das Training des Maschinenlern-Modells kann in einem zweiten Schritt mittels Transfer Learning basierend auf der Mehrzahl von Messdatensätzen fortgeführt werden. Dies bietet das Potential den Einfluss von Ungenauigkeiten des Modells oder Simulationsungenauigkeiten auf das Diagnosesystem durch das Nachtrainieren mit Messungen zu verringern. Allgemeines, gelerntes Wissen über die im Modell und der Simulation hinterlegten Zusammenhänge können im Maschinenlern-Modell erhalten werden.

Fig. 2e ein Beispiel eines Transfer Learning-Ansatzes. Hier stehen die Messdaten des Normalzustands und abnormalen Zustands zur Verfügung, wobei die Messdaten des Normalzustands für die modellbasierte Datenvermehrung/Datenaugmentierung (MDA) verwendet werden. Daraus werden, wie auch in Fign. 2c gezeigt, die jeweiligen synthetischen Datensätze erstellt. Diese werden zum Training des Maschinenlern-Modells verwendet, entweder eines Maschinenlern-Modells mit mehreren Ausgängen oder einem Maschinenlern-Modell mit einem Ausgang – d.h. in dem ersten Schritt muss das Maschinenlern-Modell noch nicht zwangsläufig auf die Klassifizierung trainiert werden, sondern es kann beispielsweise auch auf Zwischenwerte trainiert werden. Mit Hilfe der Messdaten kann anschließend ein Transfer Learning, etwa durch Feinanpassung (auch engl. Fine Tuning, FT) oder durch Merkmalsextraktion (Feature Extraction, FE) durchgeführt werden. Durch diesen zweiten Schritt kann das Maschinenlern-Modell nun zum Klassifikator trainiert werden.

Beispielsweise kann eine der der folgenden Transfer Learning-Ansätze verwendet werden. Beispielsweise kann das Maschinenlern-Modell in dem ersten Schritt basierend auf den synthetischen Trainingsdatensätzen als Klassifikator trainiert werden, der direkt zur Klassifizierung des Zustands des technischen Bauteils verwendet werden kann. Alternativ kann das Maschinenlern-Modell im ersten Schritt als eigenständiger Merkmalsextraktor trainiert werden. Dabei wird das vortrainierte Modell oder ein Teil des Modells verwendet, um den Datensatz vorzuverarbeiten und relevante Merkmale zu extrahieren. Alternativ kann das Maschinenlern-Modell im ersten Schritt als integrierter Merkmalsextraktor trainiert werden. Das vortrainierte Modell oder ein Teil des Modells kann so in ein neues Modell integriert werden, aber die Schichten des vortrainierten Modells können während des Trainings eingefroren werden. Alternativ kann das Maschinenlern-Modell im ersten Schritt als Gewichtsinitialisierung dienen. Das vortrainierte Modell oder ein Teil des Modells kann in ein neues Modell integriert werden, und die Schichten des vortrainierten Modells können zusammen mit dem neuen Modell trainiert. Die beiden letztgenannten Alternativen werden im Folgenden vertieft.

In den Beispielen der Fign. 2f und 2g wird davon ausgegangen, dass das Maschinenlern-Modell als mehrschichtiges, künstliches neuronales Netz, insbesondere als mehrschichtiges Perzeptron (engl. Multi-Layer Perceptron, MLP) implementiert ist. In anderen Worten hat das Maschinenlern-Modell der Fign. 2f und 2g eine Eingabeschicht, eine Ausgabeschicht und ein oder mehrere verborgene Schichten (engl. Hidden Layer).

In Fig. 2f wird ein Beispiel eines Transfer Learning-Ansatzes gezeigt, der auf einer Feineinstellung des Maschinenlern-Modells basiert, d.h., es werden die Schichten des vortrainierten Maschinenlern-Modells teilweise eingefroren. In anderen Worten kann das Maschinenlern-Modell eine Mehrzahl von Schichten umfassen. Die Gewichte zumindest einer Schicht der Mehrzahl von Schichten sind während des Transfer Learning eingefroren. In Fig. 2f sind beispielsweise die Gewichte der Eingabeschicht und der ersten verborgene Schicht eingefroren, während die Gewichte der zweiten verborgenen Schicht und der Ausgabeschicht mittels der Feinanpassung angepasst werden können. Die Feinabstimmung geht davon aus, dass das Wissen und die Strukturen eines bereits trainierten MLP für die neue Domäne nützlich sein können, aber eine zusätzliche Anpassung des MLP an die neue Domäne notwendig ist. Obwohl das MLP bereits mit Daten und verschiedenen Wahrscheinlichkeitsverteilungen trainiert wurde, die sich von der neuen Domäne unterscheiden können, wird dieses bereits trainierte MLP als Grundmodell verwendet. Die Übertragung auf die Messdatensätze erfolgt, indem die Ausgabeschicht oder die letzten Schichten oder mindestens eine ausgewählte Schicht des MLP mit den neuen domänenspezifischen Daten (Mehrzahl von Messdatensätzen) neu trainiert werden (Feinabstimmung). Die Gewichte der anderen Schichten des MLP werden während des neuen Trainingsvorgangs nicht verändert (Einfrieren), wie in Fig. 2f dargestellt.

Fig. 2g zeigt dagegen ein Beispiel eines Transfer Learning-Ansatzes, der auf einer Merkmalsextraktion basiert. Ein Ansatz der Merkmalsextraktion ist die Übertragung eines bestehenden Maschinenlern-Modells auf eine neue Aufgabe. Das Ziel des Transferlernens mittels Merkmalsextraktion ist also, den Teil eines Maschinenlern-Modells, der die Informationen über Merkmale und deren Verteilung gelernt hat, wiederzuverwenden und die Aufgabe des Maschinenlern-Modells anzupassen. Dazu wird der Teil, der für die Klassifikation zuständig ist, vom vortrainierten Maschinenlern-Modell getrennt (visualisiert durch die Schere in Fig. 2g). Der verbleibende Teil wird als Basismodell für die neue Klassifikationsaufgabe verwendet, um ein neues Maschinenlern-Modell zu trainieren, wie in Fig. 2g dargestellt. Zu diesem Zweck wird am Ende eine neue Struktur für die Klassifizierung hinzugefügt. Diese hinzugefügte Struktur wird dann neu basierend auf Mehrzahl von Messdatensätzen trainiert, um die Vorhersagefunktion für die neue Aufgabe anzupassen. Dabei können die Gewichte der übrigen Schichten ebenfalls angepasst werden.

Maschinenlern-Algorithmen basieren normalerweise auf einem Maschinenlern-Modell. Anders ausgedrückt, der Begriff „Maschinenlern-Algorithmus“ kann einen Satz von Anweisungen bezeichnen, die verwendet werden können, um ein Maschinenlern-Modell zu erstellen, zu trainieren oder zu verwenden. Der Begriff „Maschinenlern-Modell“ kann eine Datenstruktur und/oder einen Satz von Regeln bezeichnen, die/der das erlernte Wissen darstellt (z. B. basierend auf dem durch den Maschinenlern-Algorithmus ausgeführten Training). Bei Ausführungsbeispielen kann die Verwendung eines Maschinenlern-Algorithmus die Verwendung eines zugrundeliegenden Maschinenlern-Modells (oder einer Mehrzahl von zugrundeliegenden Maschinenlern-Modellen) implizieren. Die Verwendung eines Maschinenlern-Modells kann implizieren, dass das Maschinenlern-Modell und/oder die Datenstruktur/der Satz von Regeln, welche das Maschinenlern-Modell ist/sind, durch einen Maschinenlern-Algorithmus trainiert wird.

Beispielsweise kann das Maschinenlern-Modell ein künstliches neuronales Netz (ANN; artificial neural network) sein. ANNs sind Systeme, die durch biologische neuronale Netze inspiriert sind, wie sie in einer Netzhaut oder einem Gehirn zu finden sind. ANNs umfassen eine Mehrzahl von zwischenverbundenen Knoten und eine Mehrzahl von Verbindungen, sogenannte Kanten (edges), zwischen den Knoten. Es gibt normalerweise drei Knotentypen, Eingabeknoten, die Eingabewerte empfangen, versteckte Knoten, die (nur) mit anderen Knoten verbunden sind, und Ausgabeknoten, die Ausgabewerte bereitstellen. Jeder Knoten kann ein künstliches Neuron darstellen. Jede Kante kann Informationen senden, von einem Knoten zum anderen. Die Ausgabe eines Knoten kann als eine (nichtlineare) Funktion der Eingaben definiert sein (z.B. der Summe seiner Eingaben). Die Eingaben eines Knoten können in der Funktion basierend auf einem „Gewicht“ der Kante oder des Knoten, der die Eingabe bereitstellt, verwendet werden. Das Gewicht von Knoten und/oder von Kanten kann in dem Lernprozess angepasst werden. Anders ausgedrückt, das Training eines künstlichen neuronalen Netzes kann ein Anpassen der Gewichte der Knoten und/oder Kanten des künstlichen neuronalen Netzes umfassen, d. h. um eine erwünschte Ausgabe für eine bestimmte Eingabe zu erreichen.

Alternativ kann das Maschinenlern-Modell eine Support-Vector-Machine, ein Random-Forest-Modell oder ein Gradient-Boosting-Modell sein. Support Vector Machines (d. h. Stützvektornetze) sind Supervised Learning-Modelle mit zugeordneten Lernalgorithmen, die verwendet werden können, um Daten zu analysieren (z. B. in einer Klassifizierungs- oder

Regressionsanalyse). Support Vector Machines können durch Bereitstellen einer Eingabe mit einer Mehrzahl von Trainingseingabewerten, die zu einer von zwei Kategorien gehören, trainiert werden. Alternativ kann das Maschinenlern-Modell ein bayessches Netz sein, das ein probabilistisches gerichtetes azyklisches graphisches Modell ist. Ein bayessches Netz kann einen Satz von Zufallsvariablen und ihre bedingten Abhängigkeiten unter Verwendung eines gerichteten azyklischen Graphen darstellen. Alternativ kann das Maschinenlern-Modell auf einem genetischen Algorithmus basieren, der ein Suchalgorithmus und heuristische Technik ist, die den Prozess der natürlichen Selektion imitiert.

Die Schnittstelle 22 kann beispielsweise einem oder mehreren Eingängen und/oder einem oder mehreren Ausgängen zum Empfangen und/oder Übertragen von Informationen entsprechen, etwa in digitalen Bitwerten, basierend auf einem Code, innerhalb eines Moduls, zwischen Modulen, oder zwischen Modulen verschiedener Entitäten.

Beispielsweise können die ein oder mehreren Prozessoren 24 einem beliebigen Controller oder Prozessor oder einer programmierbaren Hardwarekomponente entsprechen. Beispielsweise kann die Funktionalität der ein oder mehreren Prozessoren 24 auch als Software realisiert sein, die für eine entsprechende Hardwarekomponente programmiert ist. Insofern können die ein oder mehreren Prozessoren 24 als programmierbare Hardware mit entsprechend angepasster Software implementiert sein. Dabei können beliebige Prozessoren, wie Digitale Signalprozessoren (DSPs) zum Einsatz kommen. Ausführungsbeispiele sind dabei nicht auf einen bestimmten Typ von Prozessor eingeschränkt. Es sind beliebige Prozessoren oder auch mehrere Prozessoren zur Implementierung denkbar.

Die ein oder mehreren Speichergeräte 26 können beispielsweise zumindest ein Element der Gruppe von computerlesbares Speichermedium, magnetisches Speichermedium, optisches Speichermedium, Festplatte, Flash-Speicher, Diskette, Zufallszugriffsspeicher (auch engl. Random Access Memory), Programmable Read Only Memory (PROM), Erasable Programmable Read Only Memory (EPROM), Electronically Erasable Programmable Read Only Memory (EEPROM), und Netzwerkspeicher umfassen.

Neben der Generierung der Trainingsdaten und dem Training des Maschinenlern-Modell ist ein weiterer Aspekt der vorliegenden Offenbarung der Einsatz des Maschinenlern-Modells zur Vorhersage des Zustands eines technischen Bauteils. Die folgende Beschreibung bezieht

sich auf ein Verfahren, eine Vorrichtung und ein entsprechendes Computerprogramm, sowie auf ein System. Merkmale, die im Zusammenhang des Verfahrens eingeführt werden, können daher auch in die entsprechende Vorrichtung, das Computerprogramm und das System übernommen werden (und umgekehrt).

Fig. 3a zeigt ein Flussdiagramm eines Beispiels eines computer-implementierten Verfahrens zum Vorhersagen eines Zustands eines technischen Bauteils. Das Verfahren umfasst ein Erhalten 310 eines Messdatensatzes über das technische Bauteil 40 (gezeigt in Fig. 3b), etwa von ein oder mehreren Sensoren 42, die Eingabe-Messdaten und/oder Ausgabe-Messdaten über das technische Bauteil erzeugen. Das Verfahren umfasst ferner ein Bereitstellen 320 von Messdaten des Messdatensatzes für das Maschinenlern-Modell. Das Maschinenlern-Modell gemäß dem Verfahren, der Vorrichtung und dem Computer-Programm von Fign. 2a bis 2f trainiert. Das Verfahren umfasst ferner ein Vorhersagen 330 des Zustands des technischen Bauteils basierend auf einer Ausgabe des Maschinenlern-Modells. Optional umfasst das Verfahren ferner ein Ausgeben 340 eines Signals über den vorhergesagten Zustand. Beispielsweise kann das Signal je nach Zustand (Normalzustand, abnormaler Zustand, Vor-Fehlerzustand, Fehlerzustand) einen anderen Wert annehmen oder entsprechende kodierte Informationen enthalten.

Fig. 3b zeigt ein Blockdiagramm eines Beispiels einer computer-implementierten Vorrichtung zum Vorhersagen eines Zustands eines technischen Bauteils und eines Systems. Die Vorrichtung 30 umfasst ein oder mehreren Prozessoren 34 und ein oder mehreren Speichereinrichtungen 36. Optional umfasst die Vorrichtung 30 ferner eine Schnittstelle 32. Die Vorrichtung 30 ist ausgebildet zum Durchführen zumindest des Verfahrens von Fig. 3a. Optional kann die Vorrichtung 30 ferner ausgebildet sein, um das Verfahren von Fig. 1a und/oder das Verfahren von Fig. 2a auszuführen. Dabei wird die Funktionalität der Vorrichtung 30 von den ein oder mehreren Prozessoren 34 der Vorrichtung bereitgestellt, unter Zuhilfenahme der optionalen Schnittstelle 32 (etwa zum Erhalten des Messdatensatzes und zur Ausgabe Signals über den vorhergesagten Zustand) und der ein oder mehreren Speichereinrichtungen (etwa zum Speichern des Maschinenlern-Modells). Beispielsweise kann die computerimplementierte Vorrichtung 30 ausgebildet sein, um den Zustand des technischen Bauteils 40 vorherzugsagen.

Fig. 3b zeigt ferner ein System umfassend die Vorrichtung 30 und das technische Bauteil 40. Optional kann das System ferner die ein oder mehreren Sensoren 42 umfassen. Beispielsweise können die ein oder mehreren Sensoren einen oder mehrere Sensoren der Gruppe von einen Stromsensor, einen Spannungssensor, einen Audio-Sensor, einen Vibrations-Sensor, eine Kamera (etwa eine Wärmebildkamera), ein Temperatursensor, einen Wettersensor, einen Drehzahlsensor, und einen Kraftsensor umfassen. Entsprechen kann auch der Messdatensatz ein oder mehrere von Messdaten eines Stromsensors, Messdaten eines Spannungssensors, Messdaten eines Audio-Sensors (etwa eines Analog-Digital-Wandlers, der ein Mikrofonsignal wandelt), Messdaten eines Vibrations-Sensors, Messdaten (etwa Bilddaten) einer Kamera (etwa einer Wärmebildkamera), Messdaten eines Temperatursensors, Messdaten eines Wettersensors, Messdaten eines Drehzahlsensors und Messdaten eines Kraftsensors umfassen. Beispielsweise können die Messdaten ähnlich implementiert sein, wie die Messdaten, die in Zusammenhang mit den Fign. 1a bis 1f eingeführt werden. Insbesondere können die Messdaten auch vorverarbeiteten Daten entsprechen und/oder extrahierten Merkmalen entsprechen.

Im Zusammenhang mit den Fign. 1a bis 1f wurde bereits darauf hingewiesen, dass das vorgeschlagene Konzept insbesondere auch für technische Bauteile von Energieanlagen genutzt werden kann. Insbesondere kann das Maschinenlern-Modell, und damit das Verfahren, die Vorrichtung, das Computerprogramm und das System beispielsweise bei einem Transformator zur Detektion und/oder Klassifizierung von Veränderungen am Aktivteil, zur Detektion und/oder zur Klassifizierung von Teilentladungen, und/oder zur Detektion und/oder Klassifizierung von Temperaturveränderungen verwendet werden.

Das Maschinenlern-Modell, und damit das Verfahren, die Vorrichtung, das Computerprogramm und das System kann beispielsweise bei Laststufenschaltern zur Detektion und/oder Klassifizierung von Abnutzung, Schäden oder Fehlern der beweglichen Komponenten, zur Detektion und/oder Klassifizierung von Schäden oder Fehlern an elektrischen Komponenten, und/oder zur Detektion und/oder Klassifizierung nicht korrekt ausgeführter Schalthandlungen genutzt werden.

Das Maschinenlern-Modell, und damit das Verfahren, die Vorrichtung, das Computerprogramm und das System kann beispielsweise bei Leistungsschaltern, Trennschaltern oder Lasttrennschalter zur Detektion und/oder Klassifizierung von Abnutzung, Schäden oder Fehlern der beweglichen Komponenten, zur Detektion und/oder Klassifizierung von Schäden oder

Fehlern an elektrischen Komponenten, zur Detektion und/oder Klassifizierung nicht korrekt ausgeführter Schalthandlungen, zur Detektion und/oder Klassifizierung von Leckage, Leckagegrads oder Leckageorts von Füllgasen oder Füllflüssigkeiten und/oder zur Bestimmung, Detektion und/oder Klassifizierung des Düsenabbrands genutzt werden.

Das Maschinenlern-Modell, und damit das Verfahren, die Vorrichtung, das Computerprogramm und das System kann beispielsweise bei Schaltanlagen zur Detektion und/oder Klassifizierung von Abnutzung, Schäden oder Fehlern der beweglichen Komponenten, zur Detektion und/oder Klassifizierung von Schäden oder Fehlern an elektrischen Komponenten, zur Detektion und/oder Klassifizierung von Leckage, Leckagegrads oder Leckageorts von Füllgasen oder Füllflüssigkeiten und/oder zur Detektion und/oder Klassifizierung von Temperaturveränderungen genutzt werden.

Das Maschinenlern-Modell, und damit das Verfahren, die Vorrichtung, das Computerprogramm und das System kann bei Kabeln und Muffen zur Detektion und/oder Klassifizierung von Teilentladungen, zur Detektion und/oder Klassifizierung der Änderung des Verlustfaktors, zur Detektion und/oder Klassifizierung von Wassereindringen, zur Detektion und/oder Klassifizierung von Raumladungsbildung, und/oder zur Detektion und/oder Klassifizierung von Temperaturveränderungen verwendet werden.

Das Maschinenlern-Modell, und damit das Verfahren, die Vorrichtung, das Computerprogramm und das System kann beispielsweise bei Hochspannungsdurchführungen zur Detektion und/oder Klassifizierung von Teilentladungen, zur Detektion und/oder Klassifizierung der Änderung des Verlustfaktors, zur Detektion und/oder Klassifizierung der Änderung der Kapazität und/oder zur Detektion und/oder Klassifizierung von Temperaturveränderungen verwendet werden.

Das Maschinenlern-Modell, und damit das Verfahren, die Vorrichtung, das Computerprogramm und das System kann beispielsweise bei Freileitungen oder Freileitungsarmaturen zur Detektion und/oder Klassifizierung von Teilentladungen, zur Detektion und/oder Klassifizierung der Änderung des Verlustfaktors, und/oder zur Detektion und/oder Klassifizierung von Temperaturveränderungen verwendet werden.

Die modellbasierte Datenvermehrung ermöglicht Diagnosesysteme für die beschriebenen Anwendungsmöglichkeiten, unter anderem, zu erstellen, die höhere Erfolgsgrade bei der Diagnose erzielen als Diagnosesysteme, die ohne die modellbasierte Datenvermehrung erstellt werden.

Die Schnittstelle 32 kann beispielsweise einem oder mehreren Eingängen und/oder einem oder mehreren Ausgängen zum Empfangen und/oder Übertragen von Informationen entsprechen, etwa in digitalen Bitwerten, basierend auf einem Code, innerhalb eines Moduls, zwischen Modulen, oder zwischen Modulen verschiedener Entitäten.

Beispielsweise können die ein oder mehreren Prozessoren 34 einem beliebigen Controller oder Prozessor oder einer programmierbaren Hardwarekomponente entsprechen. Beispielsweise kann die Funktionalität der ein oder mehreren Prozessoren 34 auch als Software realisiert sein, die für eine entsprechende Hardwarekomponente programmiert ist. Insofern können die ein oder mehreren Prozessoren 34 als programmierbare Hardware mit entsprechend angepasster Software implementiert sein. Dabei können beliebige Prozessoren, wie Digitale Signalprozessoren (DSPs) zum Einsatz kommen. Ausführungsbeispiele sind dabei nicht auf einen bestimmten Typ von Prozessor eingeschränkt. Es sind beliebige Prozessoren oder auch mehrere Prozessoren zur Implementierung denkbar.

Die ein oder mehreren Speichergeräte 36 können beispielsweise zumindest ein Element der Gruppe von computerlesbares Speichermedium, magnetisches Speichermedium, optisches Speichermedium, Festplatte, Flash-Speicher, Diskette, Zufallszugriffsspeicher (auch engl. Random Access Memory), Programmable Read Only Memory (PROM), Erasable Programmable Read Only Memory (EPROM), Electronically Erasable Programmable Read Only Memory (EEPROM), und Netzwerkspeicher umfassen.

Mehr Details und Aspekte des Verfahrens, der Vorrichtung, des Systems und des Computerprogramms werden in Verbindung mit dem Konzept oder Beispielen genannt, die vorher (z.B. Fig. 1a bis 2g) beschrieben wurden. Das Verfahren, die Vorrichtung, das System und das Computerprogramm kann ein oder mehrere zusätzliche optionale Merkmale umfassen, die ein oder mehreren Aspekten des vorgeschlagenen Konzepts oder der beschriebenen Beispiele entsprechen, wie sie vorher oder nachher beschrieben wurden.

Die Aspekte und Merkmale, die im Zusammenhang mit einem bestimmten der vorherigen Beispiele beschrieben sind, können auch mit einem oder mehreren der weiteren Beispiele kombiniert werden, um ein identisches oder ähnliches Merkmal dieses weiteren Beispiels zu ersetzen oder um das Merkmal in das weitere Beispiel zusätzlich einzuführen.

Beispiele können weiterhin ein (Computer-)Programm mit einem Programmcode zum Ausführen eines oder mehrerer der obigen Verfahren sein oder sich darauf beziehen, wenn das Programm auf einem Computer, einem Prozessor oder einer sonstigen programmierbaren Hardwarekomponente ausgeführt wird. Schritte, Operationen oder Prozesse von verschiedenen der oben beschriebenen Verfahren können also auch durch programmierte Computer, Prozessoren oder sonstige programmierbare Hardwarekomponenten ausgeführt werden. Beispiele können auch Programmspeichervorrichtungen, z. B. Digitaldatenspeichermedien, abdecken, die maschinen-, prozessor- oder computerlesbar sind und maschinenausführbare, prozessorausführbare oder computerausführbare Programme und Anweisungen codieren beziehungsweise enthalten. Die Programmspeichervorrichtungen können z. B. Digitalspeicher, magnetische Speichermedien wie beispielsweise Magnetplatten und Magnetbänder, Festplattenlaufwerke oder optisch lesbare Digitaldatenspeichermedien umfassen oder sein. Weitere Beispiele können auch Computer, Prozessoren, Steuereinheiten, (feld-)programmierbare Logik-Arrays ((F)PLAs = (Field) Programmable Logic Arrays),(feld-)programmierbare Gate-Arrays ((F)PGA = (Field) Programmable Gate Arrays), Grafikprozessoren (GPU = Graphics Processor Unit), anwendungsspezifische integrierte Schaltungen (ASIC = application-specific integrated circuit), integrierte Schaltungen (IC= Integrated Circuit) oder Ein-Chip-Systeme (SoC = System-on-a-Chip) abdecken, die zum Ausführen der Schritte der oben beschriebenen Verfahren programmiert sind.

Verschiedene Ausführungsbeispiele schaffen ferner ein Computerprogrammprodukt, umfassend Befehle, die bei der Ausführung des Programms durch einen Computer diesen veranlassen, zumindest eines der Verfahren gemäß einem der vorliegenden Ansprüche auszuführen.

Verschiedene Ausführungsbeispiele schaffen ferner ein Computerlesbares (Speicher)medium, umfassend Befehle, die bei der Ausführung durch einen Computer diesen veranlassen, zumindest eines der Verfahren gemäß einem der vorliegenden Ansprüche auszuführen.

Es versteht sich ferner, dass die Offenbarung mehrerer, in der Beschreibung oder den Ansprüchen offenbarter Schritte, Prozesse, Operationen oder Funktionen nicht als zwingend in der beschriebenen Reihenfolge befindlich ausgelegt werden soll, sofern dies nicht im Einzelfall explizit angegeben oder aus technischen Gründen zwingend erforderlich ist. Daher wird durch die vorhergehende Beschreibung die Durchführung von mehreren Schritten oder Funktionen nicht auf eine bestimmte Reihenfolge begrenzt. Ferner kann bei weiteren Beispielen ein einzelner Schritt, eine einzelne Funktion, ein einzelner Prozess oder eine einzelne Operation mehrere Teilschritte, -funktionen, -prozesse oder -operationen einschließen und/oder in dieselben aufgebrochen werden.

Wenn einige Aspekte in den vorhergehenden Abschnitten im Zusammenhang mit einer Vorrichtung oder einem System beschrieben wurden, sind diese Aspekte auch als eine Beschreibung des entsprechenden Verfahrens zu verstehen. Dabei kann beispielsweise ein Block, eine Vorrichtung oder ein funktionaler Aspekt der Vorrichtung oder des Systems einem Merkmal, etwa einem Verfahrensschritt, des entsprechenden Verfahrens entsprechen. Entsprechend dazu sind Aspekte, die im Zusammenhang mit einem Verfahren beschrieben werden, auch als eine Beschreibung eines entsprechenden Blocks, eines entsprechenden Elements, einer Eigenschaft oder eines funktionalen Merkmals einer entsprechenden Vorrichtung oder eines entsprechenden Systems zu verstehen.

Die folgenden Ansprüche werden hiermit in die detaillierte Beschreibung aufgenommen, wobei jeder Anspruch als getrenntes Beispiel für sich stehen kann. Ferner ist zu beachten, dass – obwohl ein abhängiger Anspruch sich in den Ansprüchen auf eine bestimmte Kombination mit einem oder mehreren anderen Ansprüchen bezieht – andere Beispiele auch eine Kombination des abhängigen Anspruchs mit dem Gegenstand jedes anderen abhängigen oder unabhängigen Anspruchs umfassen können. Solche Kombinationen werden hiermit explizit vorgeschlagen, sofern nicht im Einzelfall angegeben ist, dass eine bestimmte Kombination nicht beabsichtigt ist. Ferner sollen auch Merkmale eines Anspruchs für jeden anderen unabhängigen Anspruch eingeschlossen sein, selbst wenn dieser Anspruch nicht direkt als abhängig von diesem anderen unabhängigen Anspruch definiert ist.

Patentansprüche

1. Ein computer-implementiertes Verfahren zum Erzeugen von Trainingsdatensätzen zum Trainieren eines Maschinenlern-Modells zur Vorhersage über einen Zustand eines technischen Bauteils, das Verfahren umfassend:

   Erhalten (110) einer Mehrzahl von Messdatensätzen über das technische Bauteil, wobei jeder Messdatensatz zumindest ein oder mehrere Ausgangs-Messdaten umfasst;

   Ermitteln (120) von Modell-Parameterwerten von ein oder mehreren Modell-Parametern eines physikalischen Modells des technischen Bauteils basierend auf den ein oder mehreren Ausgangs-Messdaten der jeweiligen Messdatensätze;

   Bestimmen (140) einer ersten Mehrzahl von Trainingsdatensätzen;

   Durchführen (150) einer zweiten Mehrzahl von Simulationen des physikalischen Modells, um eine zweite Mehrzahl von Trainingsdatensätzen zu generieren, wobei basierend auf einer statistischen Verteilung der ermittelten Modell-Parameterwerte ein oder mehrere Modell-Parameterwerte für die jeweilige Simulation ausgewählt werden, wobei für jede Simulation zumindest ein Modell-Parameterwert außerhalb eines Hauptbereichs der statistischen Verteilung der ermittelten Modell-Parameterwerte ausgewählt wird.

2. Das Verfahren gemäß Anspruch 1, umfassend Durchführen einer ersten Mehrzahl von Simulationen des physikalischen Modells, um die erste Mehrzahl von Trainingsdatensätzen zu generieren, wobei basierend auf der statistischen Verteilung der ermittelten Modell-Parameterwerte ein oder mehrere Modell-Parameterwerte für die jeweilige Simulation ausgewählt werden.

3. Das Verfahren gemäß einem der Ansprüche 1 oder 2, wobei die erste Mehrzahl von Trainingsdatensätzen einen Normalzustand des technischen Bauteils abbilden und wobei die zweite Mehrzahl von Trainingsdatensätzen einen oder mehrere abnormale Zustände des technischen Bauteils abbilden.

4. Das Verfahren gemäß Anspruch 3, wobei das physikalische Modell dazu geeignet ist, um eine Simulation des Normalzustands und eine Simulation der ein oder mehreren abnormalen Zustände des Bauteils durchzuführen.

5. Das Verfahren gemäß einem der Ansprüche 1 bis 4, wobei die Mehrzahl von Messdatensätzen ferner ein oder mehrere Eingangs-Messdaten umfasst, wobei die Modell-Parameterwerte des physikalischen Modells ferner basierend auf den ein oder mehreren Eingangs-Messdaten ermittelt werden, wobei für die Simulationen des physikalischen Modells ferner basierend auf einer statistischen Verteilung der Eingangs-Messdaten ein oder mehrere Eingangs-Daten ausgewählt werden.

6. Das Verfahren gemäß einem der Ansprüche 1 bis 5, umfassend Bestimmen (122) der statistischen Verteilung der ermittelten Modell-Parameterwerte des physikalischen Modells, durch Unterteilen (124) der Mehrzahl von Messdatensätzen in eine Mehrzahl von Gruppen von Messdatensätzen, Ermitteln (120), für jede Gruppe von Messdatensätzen, von ein oder mehreren Modell-Parameterwerten des physikalischen Modells durch Minimierung eines Fehlers zwischen den ein oder mehreren Ausgangs-Messdaten der jeweiligen Gruppe von Messdatensätzen und entsprechenden mittels des physikalischen Modells erzeugten Ausgangsdaten, und Berechnen (126) der statistischen Verteilung der basierend auf den verschiedenen Gruppen von Messdatensätzen ermittelten Modell-Parameterwerten.

7. Das Verfahren gemäß einem der Ansprüche 1 bis 6, wobei für jede Simulation der zweiten Mehrzahl von Simulationen ein Modell-Parameterwert außerhalb des Hauptbereichs der statistischen Verteilung der ermittelten Modell-Parameterwerte und andere Modell-Parameterwerte, sofern vorhanden, basierend auf der statistischen Verteilung der ermittelten Modell-Parameterwerte ausgewählt werden.

8. Das Verfahren gemäß einem der Ansprüche 1 bis 7, wobei für zumindest eine Simulation der zweiten Mehrzahl von Simulationen zumindest zwei Modell-Parameterwerte außerhalb des Hauptbereichs der statistischen Verteilung der jeweiligen Modell-Parameterwerte ausgewählt werden, wobei die zumindest zwei Modell-Parameterwerte basierend auf einem vorbekannten Zusammenhang zwischen den zwei Modell-Parametern ausgewählt werden.

9. Das Verfahren gemäß einem der Ansprüche 1 bis 8, wobei das physikalische Modell dazu vorgesehen ist, um durch Durchführen einer Simulation basierend auf zumindest ein oder mehreren Modell-Parameterwerten ein oder mehrere Ausgangsdaten zu erzeugen.

10. Das Verfahren gemäß einem der Ansprüche 1 bis 9, wobei das technische Bauteil eine Komponente einer Maschine oder einer technischen Anlage ist,
und/oder wobei das technische Bauteil ein elektrotechnisches Bauteil ist,
und/oder wobei das technische Bauteil eines von einem Transformator, einem Laststufenschalter, einem Leistungsschalter, einem Trennschalter, einem Lasttrennschalter, einer Schaltanlage, einem Kabel, einer Muffe, einer Freileitung, einer Freileitungsarmatur und einer Hochspannungsdurchführung ist.

11. Ein computer-implementiertes Verfahren zum Trainieren eines Maschinenlern-Modells zur Vorhersage eines Zustands eines technischen Bauteils, das Verfahren umfassend:

Erhalten (210) einer ersten Mehrzahl von Trainingsdatensätzen und einer zweiten Mehrzahl von Trainingsdatensätzen, wobei die erste Mehrzahl von Trainingsdatensätzen und die zweite Mehrzahl von Trainingsdatensätzen basierend auf dem Verfahren gemäß einem der Ansprüche 1 bis 10 erzeugt sind, wobei die erste Mehrzahl von Trainingsdatensätzen einen Normalzustand des technischen Bauteils abbilden und wobei die zweite Mehrzahl von Trainingsdatensätzen einen oder mehrere abnormale Zustände des technischen Bauteils abbilden;

Trainieren (230) des Maschinenlern-Modells basierend auf der ersten Mehrzahl von Trainingsdatensätzen und basierend auf der zweiten Mehrzahl von Trainingsdatensätzen.

12. Das Verfahren gemäß Anspruch 11, ferner umfassend Erhalten (220) einer Mehrzahl von Messdatensätzen über das technische Bauteil, wobei das Training des Maschinenlern-Modells ferner auf der Mehrzahl von Messdatensätzen basiert.

13. Das Verfahren gemäß Anspruch 12, wobei die Mehrzahl von Messdatensätzen um die erste und zweite Mehrzahl von Trainingsdatensätzen erweitert werden und das Maschinenlern-Modell gemeinsam basierend auf der Mehrzahl von Messdatensätzen und der ersten und zweiten Mehrzahl von Trainingsdatensätzen trainiert wird.

14. Das Verfahren gemäß Anspruch 12, wobei das Maschinenlern-Modell in einem ersten Schritt basierend auf der ersten und zweiten Mehrzahl von Trainingsdatensätzen trainiert wird, und wobei das Training des Maschinenlern-Modells in einem zweiten Schritt mittels Transfer Learning basierend auf der Mehrzahl von Messdatensätzen fortgeführt wird.

15. Das Verfahren gemäß einem der Ansprüche 11 bis 14, wobei das Maschinenlern-Modell als Klassifikator für den Zustand des technischen Bauteils trainiert wird.

16. Ein computer-implementiertes Verfahren zum Vorhersagen eines Zustands eines technischen Bauteils, das Verfahren umfassend:

Erhalten (310) eines Messdatensatzes über das technische Bauteil;

Bereitstellen (320) von Messdaten des Messdatensatzes für ein Maschinenlern-Modell, wobei das Maschinenlern-Modell gemäß einem der Ansprüche 11 bis 15 trainiert ist; und

Vorhersagen (330) des Zustands des technischen Bauteils basierend auf einer Ausgabe des Maschinenlern-Modells.

17. Ein System (300) umfassend ein technisches Bauteil (40) und eine computerimplementierte Vorrichtung (30), wobei die computerimplementierte Vorrichtung ein oder mehrere Prozessoren (34) und ein oder mehreren Speichereinrichtungen (36) umfasst und ausgebildet ist zum Ausführen des Verfahrens von Anspruch 16, wobei die computerimplementierte Vorrichtung ausgebildet ist, um den Zustand des technischen Bauteils vorherzugsagen.

18. Ein Programm mit einem Programmcode zum Durchführen zumindest eines der Verfahren gemäß einem der Ansprüche 1 bis 16, wenn der Programmcode auf einem Computer, einem Prozessor, einem Kontrollmodul oder einer programmierbaren Hardwarekomponente ausgeführt wird.

19. Eine computerimplementierte Vorrichtung (10; 20; 30) mit ein oder mehreren Prozessoren (14; 24; 34) und ein oder mehreren Speichereinrichtungen (16; 26; 36), ausgebildet zum Durchführen zumindest eines der Verfahren gemäß einem der Ansprüche 1 bis 16.

Zusammenfassung

Konzept für eine Datenvermehrung von Trainingsdatensätzen für ein Maschinenlern-Modell zur Vorhersage eines Zustands eines technischen Bauteils

Die vorliegende Erfindung bezieht sich auf Verfahren, Vorrichtungen und Computerprogrammen zum Erzeugen von Trainingsdatensätzen zum Trainieren eines Maschinenlern-Modells zur Vorhersage über einen Zustand eines technischen Bauteils, zum Trainieren eines solchen Maschinenlern-Modells, und zum Einsatz eines solchen Maschinenlern-Modells. Das Verfahren zum Erzeugen der Trainingsdatensätzen umfasst ein Erhalten (110) einer Mehrzahl von Messdatensätzen über das technische Bauteil, wobei jeder Messdatensatz zumindest ein oder mehrere Ausgangs-Messdaten umfasst. Das Verfahren umfasst ferner ein Ermitteln (120) von Modell-Parameterwerten von ein oder mehreren Modell-Parametern eines physikalischen Modells des technischen Bauteils basierend auf den ein oder mehreren Ausgangs-Messdaten der jeweiligen Messdatensätze. Das Verfahren umfasst ferner ein Bestimmen (140) einer ersten Mehrzahl von Trainingsdatensätzen, etwa durch Durchführen einer ersten Mehrzahl von Simulationen des physikalischen Modells, wobei basierend auf einer statistischen Verteilung der ermittelten Modell-Parameterwerte ein oder mehrere Modell-Parameterwerte für die jeweilige Simulation ausgewählt werden. Das Verfahren umfasst ferner ein Durchführen (150) einer zweiten Mehrzahl von Simulationen des physikalischen Modells, um eine zweite Mehrzahl von Trainingsdatensätzen zu generieren, wobei basierend auf der statistischen Verteilung der ermittelten Modell-Parameterwerte ein oder mehrere Modell-Parameterwerte für die jeweilige Simulation ausgewählt werden, wobei für jede Simulation zumindest ein Modell-Parameterwert außerhalb eines Hauptbereichs der statistischen Verteilung der ermittelten Modell-Parameterwerte ausgewählt wird.

(Fig. 1a)

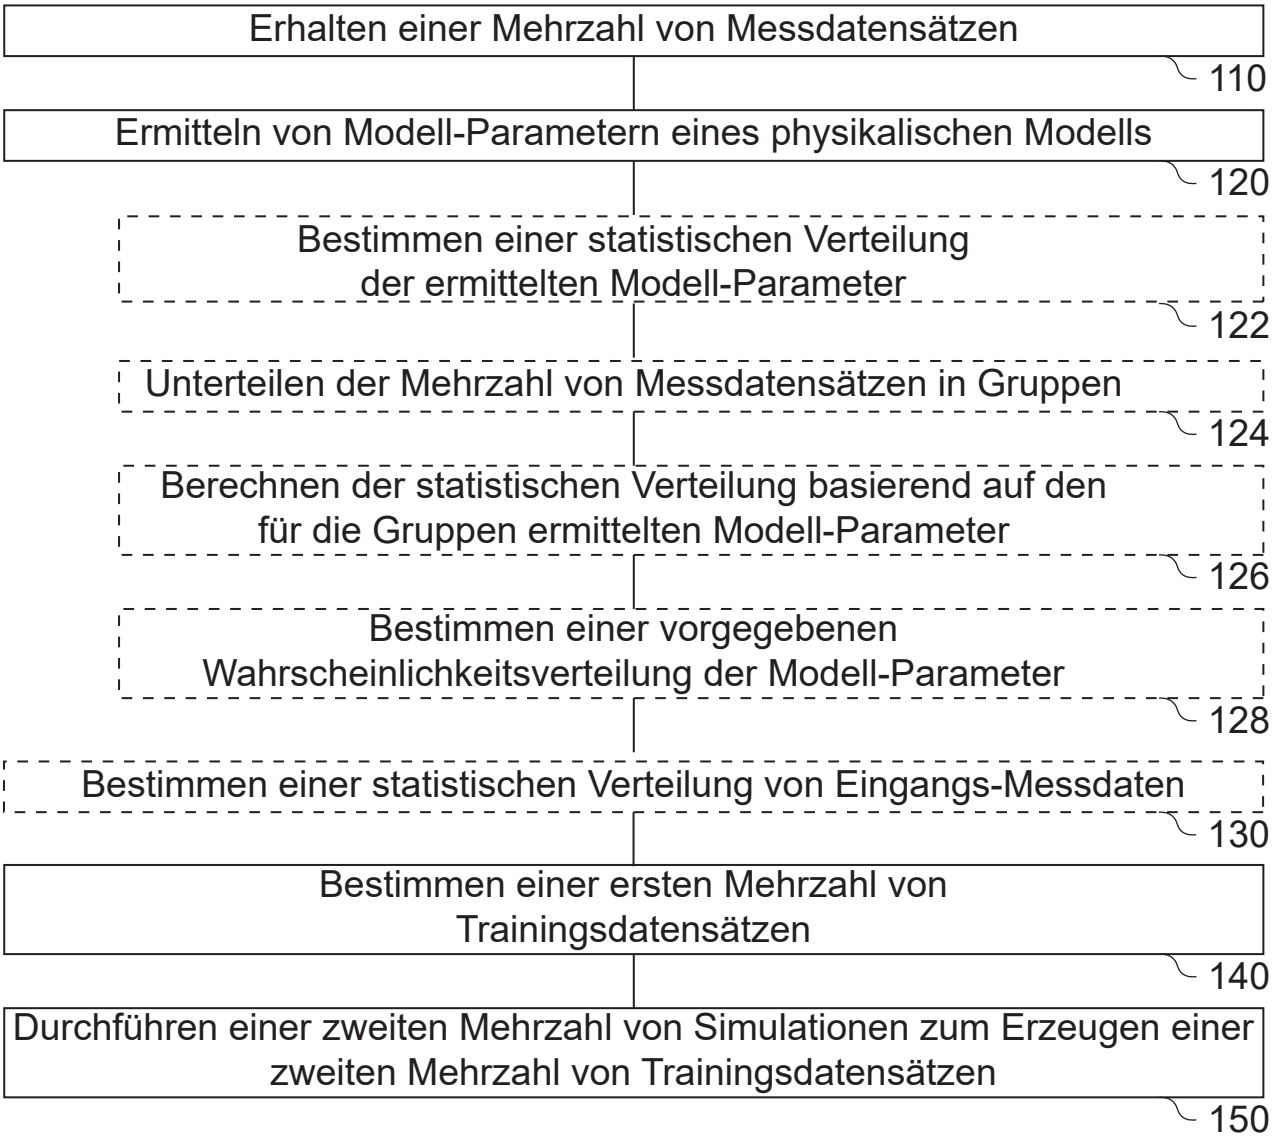
Erhalten einer Mehrzahl von Messdatensätzen
110
Ermitteln von Modell-Parametern eines physikalischen Modells
120
Bestimmen einer statistischen Verteilung der ermittelten Modell-Parameter
122
Unterteilen der Mehrzahl von Messdatensätzen in Gruppen
124
Berechnen der statistischen Verteilung basierend auf den für die Gruppen ermittelten Modell-Parameter
126
Bestimmen einer vorgegebenen Wahrscheinlichkeitsverteilung der Modell-Parameter
128
Bestimmen einer statistischen Verteilung von Eingangs-Messdaten
130
Bestimmen einer ersten Mehrzahl von Trainingsdatensätzen
140
Durchführen einer zweiten Mehrzahl von Simulationen zum Erzeugen einer zweiten Mehrzahl von Trainingsdatensätzen
150

Fig. 1a

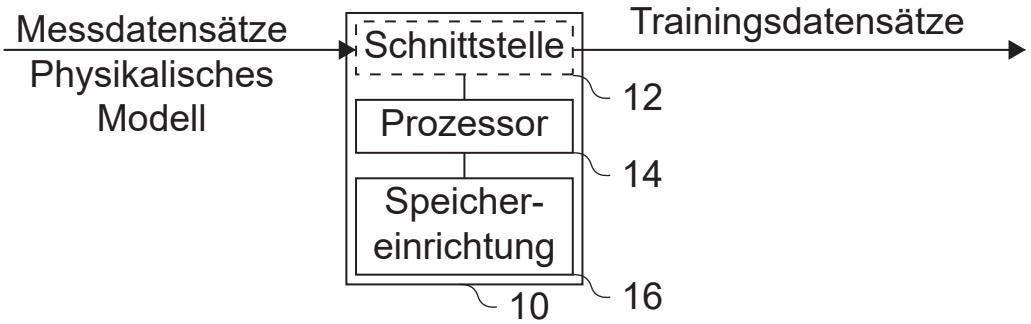
Messdatensätze
Physikalisches Modell
Schnittstelle
12
Prozessor
14
Speicher-einrichtung
16
10
Trainingsdatensätze

Fig. 1b

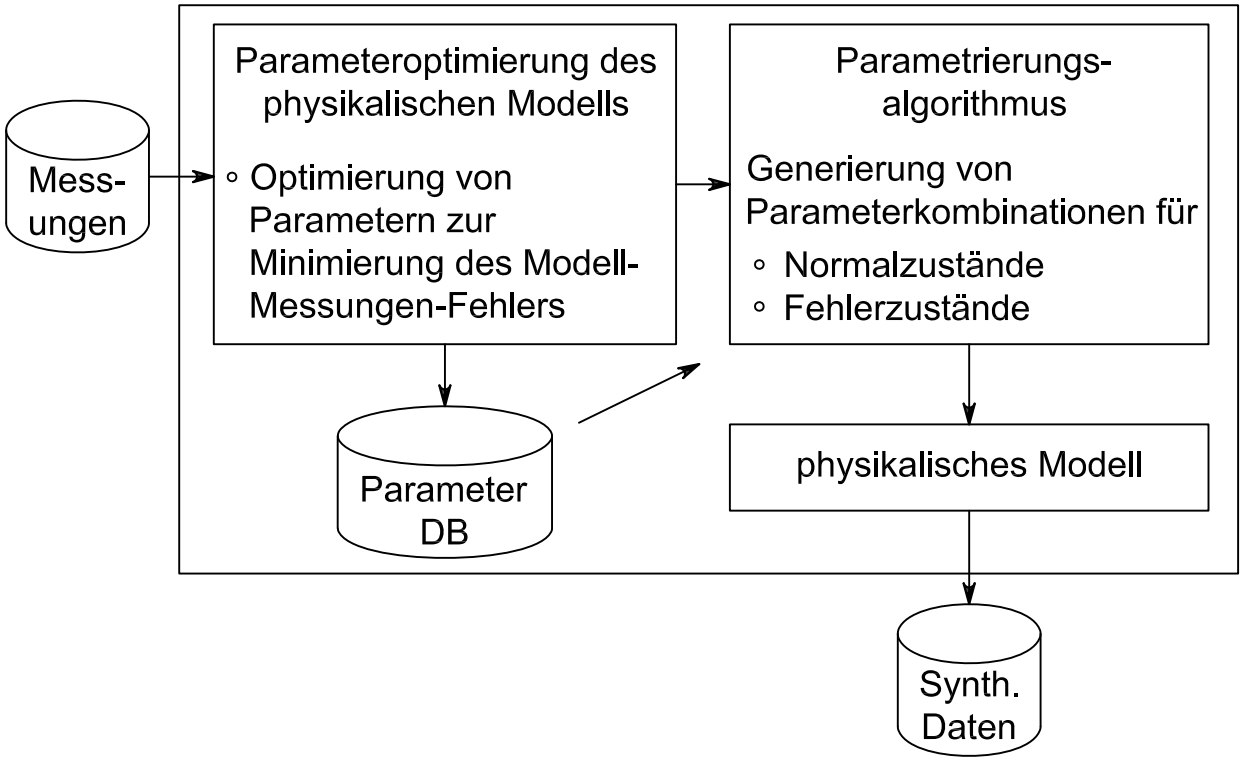
Mess-
ungen
Parameteroptimierung des physikalischen Modells
◦ Optimierung von Parametern zur Minimierung des Modell-Messungen-Fehlers
Parametrierungs-algorithmus
Generierung von Parameterkombinationen für
◦ Normalzustände
◦ Fehlerzustände
Parameter DB
physikalisches Modell
Synth. Daten

FIG. 1c

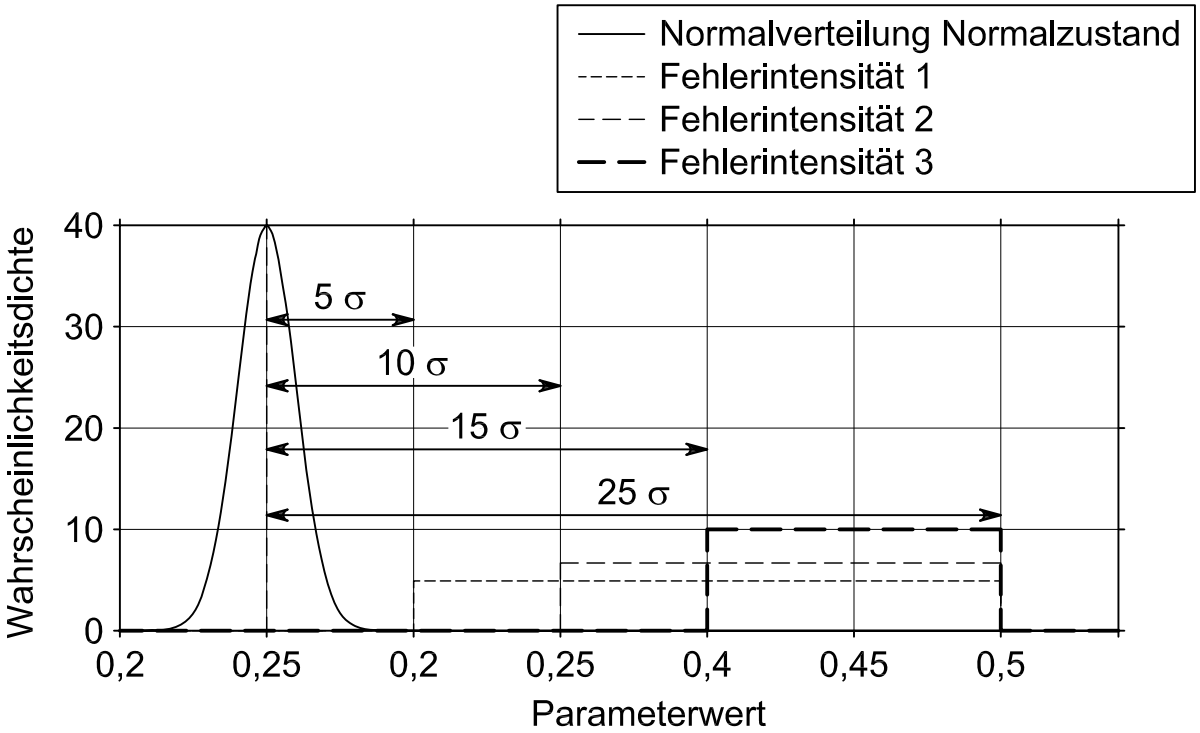
Normalverteilung Normalzustand
Fehlerintensität 1
Fehlerintensität 2
Fehlerintensität 3
Wahrscheinlichkeitsdichte
40
30
20
10
0
5 σ
10 σ
15 σ
25 σ
0,2
0,25
0,2
0,25
0,4
0,45
0,5
Parameterwert

FIG. 1e

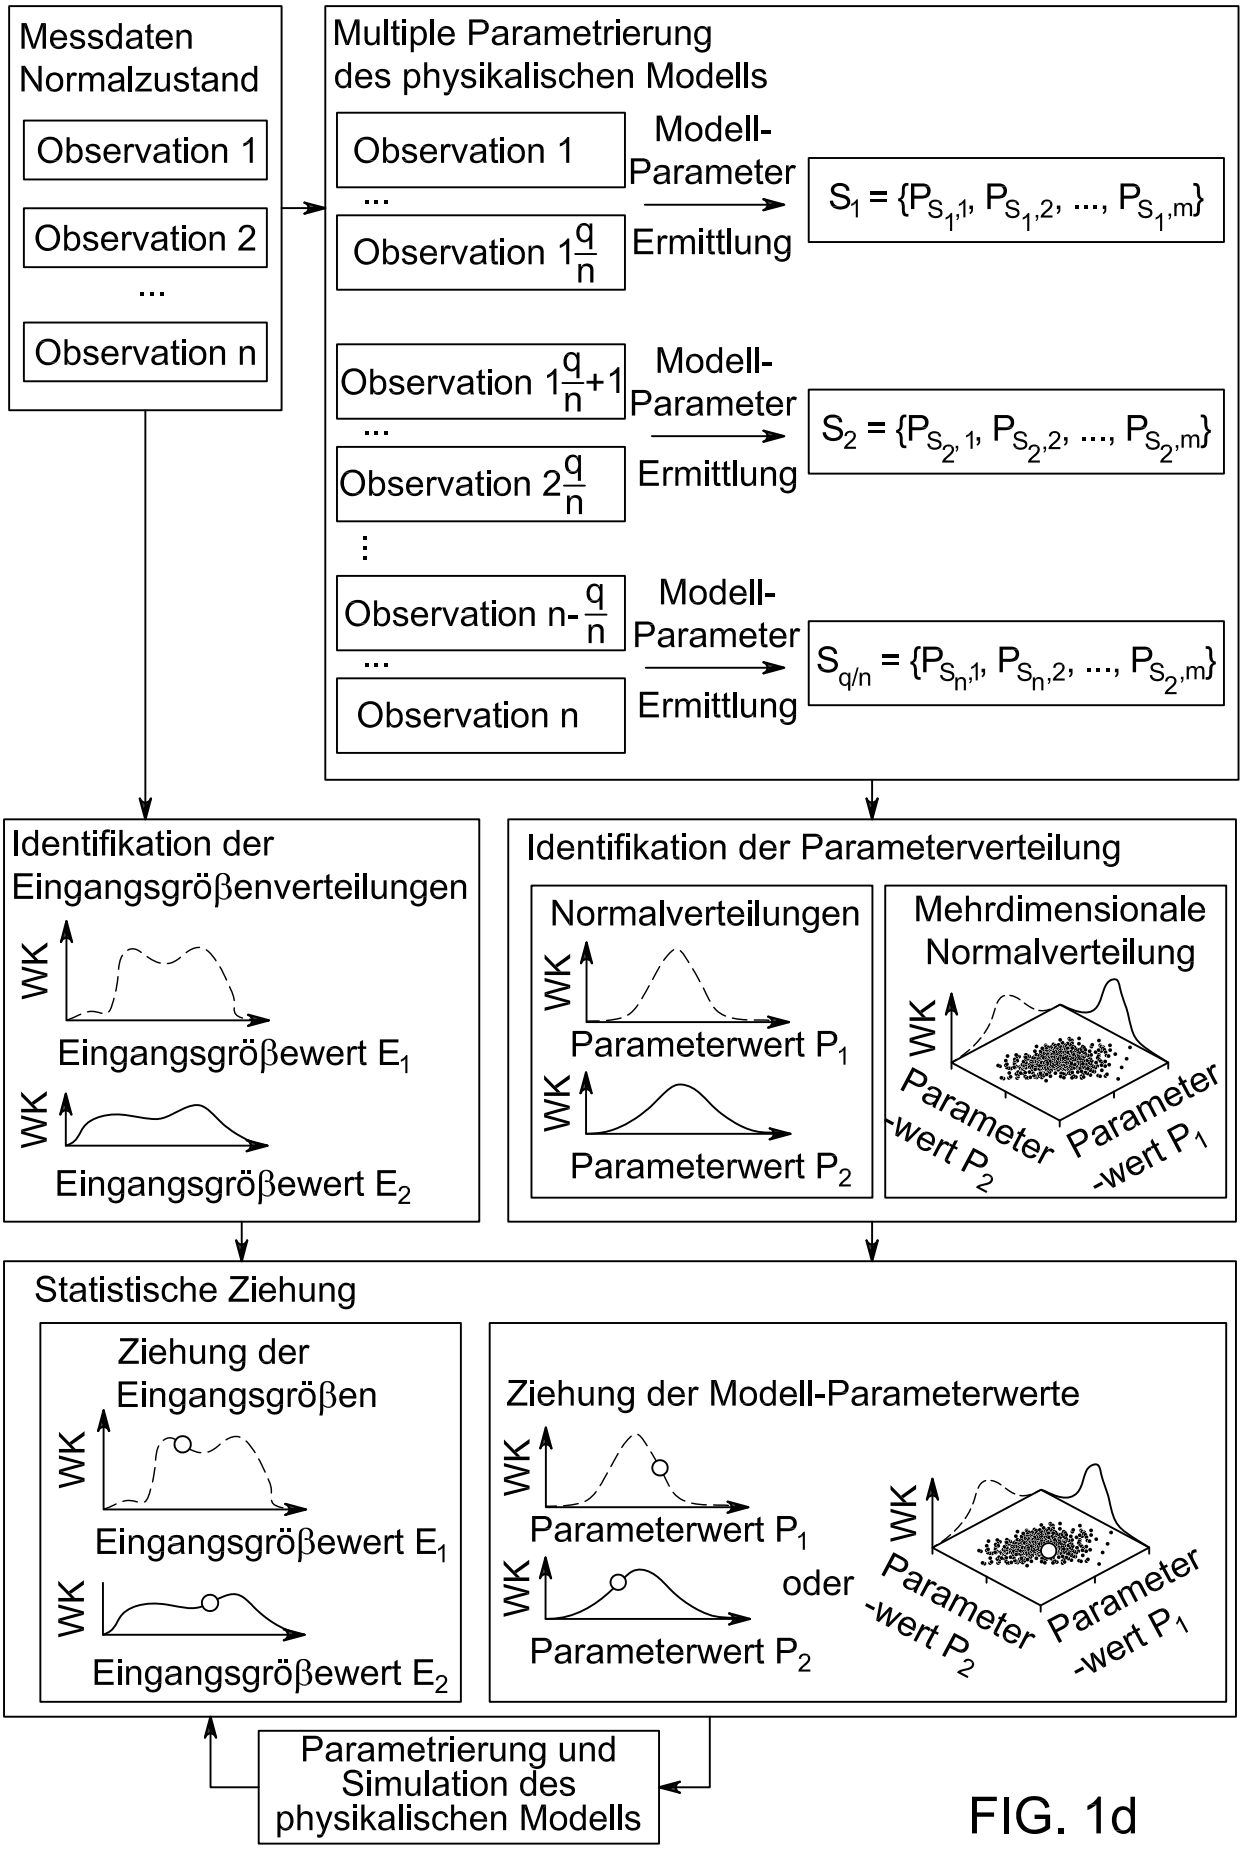
Messdaten Normalzustand
Observation 1
Observation 2
...
Observation n
Multiple Parametrierung des physikalischen Modells
Observation 1
...
Observation $1\frac{q}{n}$
Modell-Parameter Ermittlung
$S_1 = \{P_{S_1,1}, P_{S_1,2}, ..., P_{S_1,m}\}$
Observation $1\frac{q}{n}+1$
...
Observation $2\frac{q}{n}$
Modell-Parameter Ermittlung
$S_2 = \{P_{S_2,1}, P_{S_2,2}, ..., P_{S_2,m}\}$
Observation $n-\frac{q}{n}$
...
Observation n
Modell-Parameter Ermittlung
$S_{q/n} = \{P_{S_n,1}, P_{S_n,2}, ..., P_{S_2,m}\}$
Identifikation der Eingangsgrößenverteilungen
WK
Eingangsgrößewert E_1
WK
Eingangsgrößewert E_2
Identifikation der Parameterverteilung
Normalverteilungen
WK
Parameterwert P_1
WK
Parameterwert P_2
Mehrdimensionale Normalverteilung
WK
Parameter-wert P_2
Parameter-wert P_1
Statistische Ziehung
Ziehung der Eingangsgrößen
WK
Eingangsgrößewert E_1
WK
Eingangsgrößewert E_2
Ziehung der Modell-Parameterwerte
WK
Parameterwert P_1
WK
Parameterwert P_2
oder
WK
Parameter-wert P_2
Parameter-wert P_1
Parametrierung und Simulation des physikalischen Modells

FIG. 1d

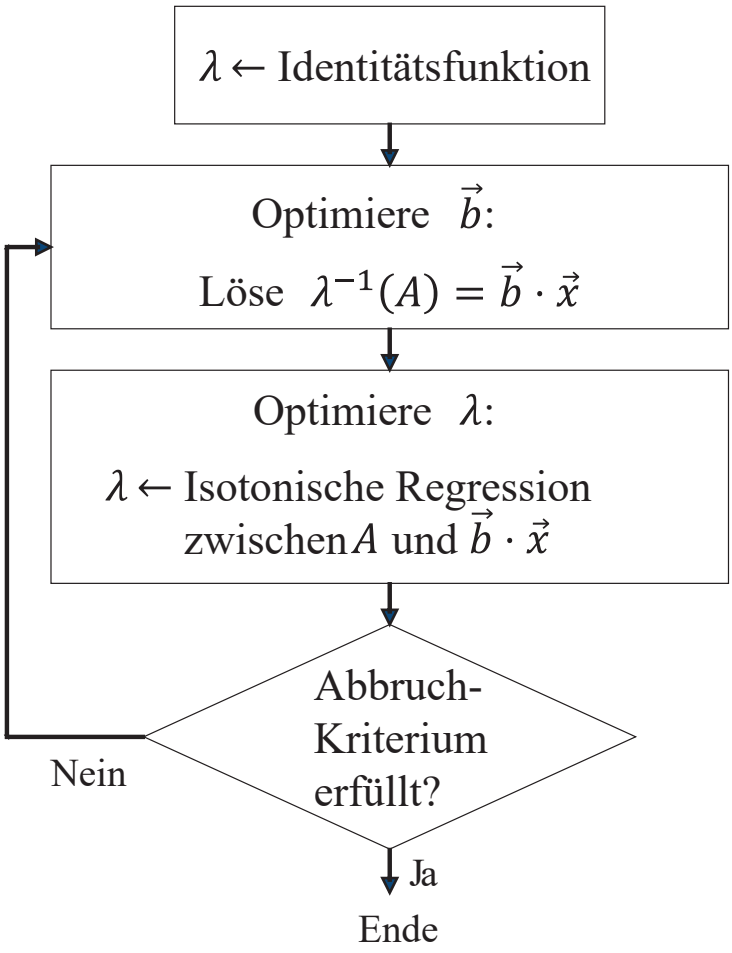
$\lambda \leftarrow$ Identitätsfunktion
Optimiere $\vec{b}$:
Löse $\lambda^{-1}(A) = \vec{b} \cdot \vec{x}$
Optimiere λ:
$\lambda \leftarrow$ Isotonische Regression zwischen A und $\vec{b} \cdot \vec{x}$
Abbruch-Kriterium erfüllt?
Nein
Ja
Ende

Fig. 1f

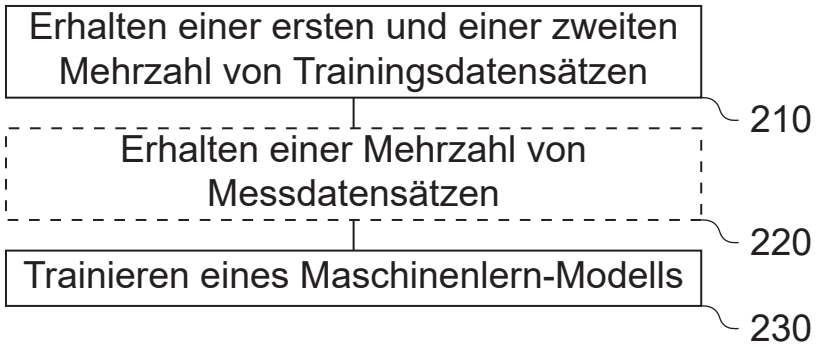
Erhalten einer ersten und einer zweiten Mehrzahl von Trainingsdatensätzen
210
Erhalten einer Mehrzahl von Messdatensätzen
220
Trainieren eines Maschinenlern-Modells
230

Fig. 2a

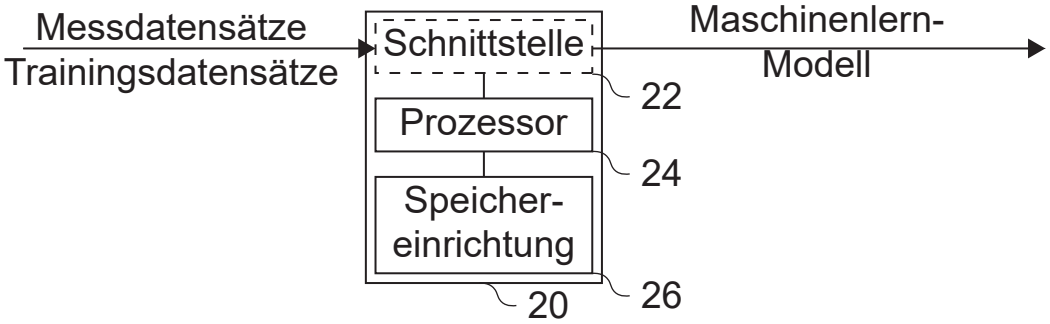
Messdatensätze
Trainingsdatensätze
Schnittstelle
22
Prozessor
24
Speicher-einrichtung
26
20
Maschinenlern-Modell

Fig. 2b

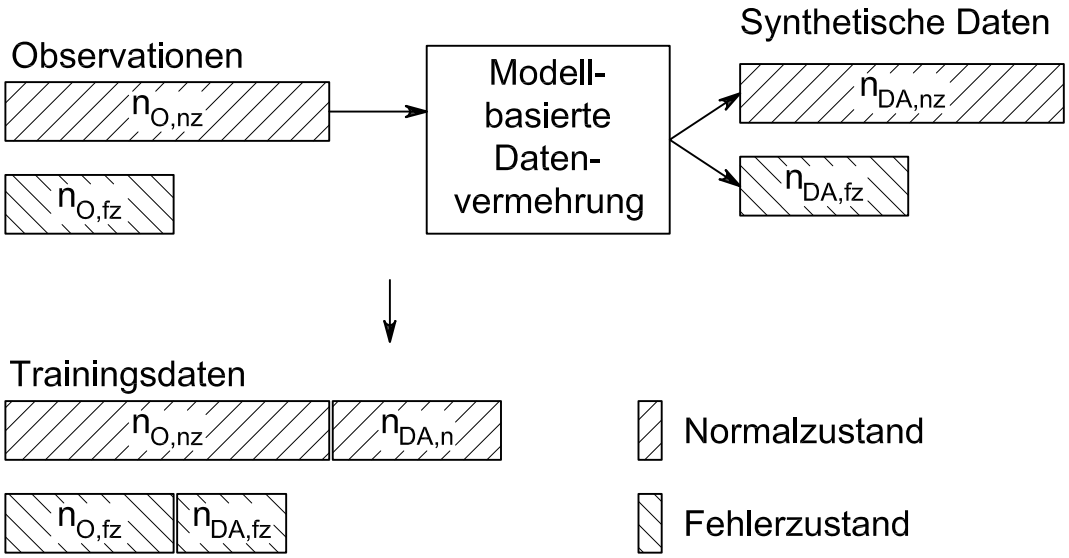
Observationen
$n_{O,nz}$
$n_{O,fz}$
Modell-
basierte
Daten-
vermehrung
Synthetische Daten
$n_{DA,nz}$
$n_{DA,fz}$
Trainingsdaten
$n_{O,nz}$
$n_{DA,n}$
$n_{O,fz}$
$n_{DA,fz}$
Normalzustand
Fehlerzustand

FIG. 2c

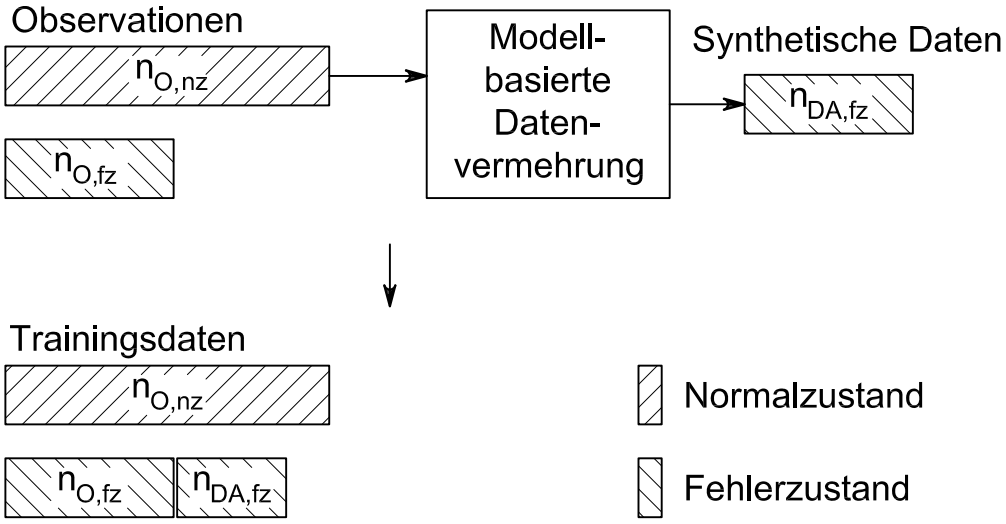
Observationen
$n_{O,nz}$
$n_{O,fz}$
Modell-
basierte
Daten-
vermehrung
Synthetische Daten
$n_{DA,fz}$
Trainingsdaten
$n_{O,nz}$
$n_{O,fz}$
$n_{DA,fz}$
Normalzustand
Fehlerzustand

FIG. 2d

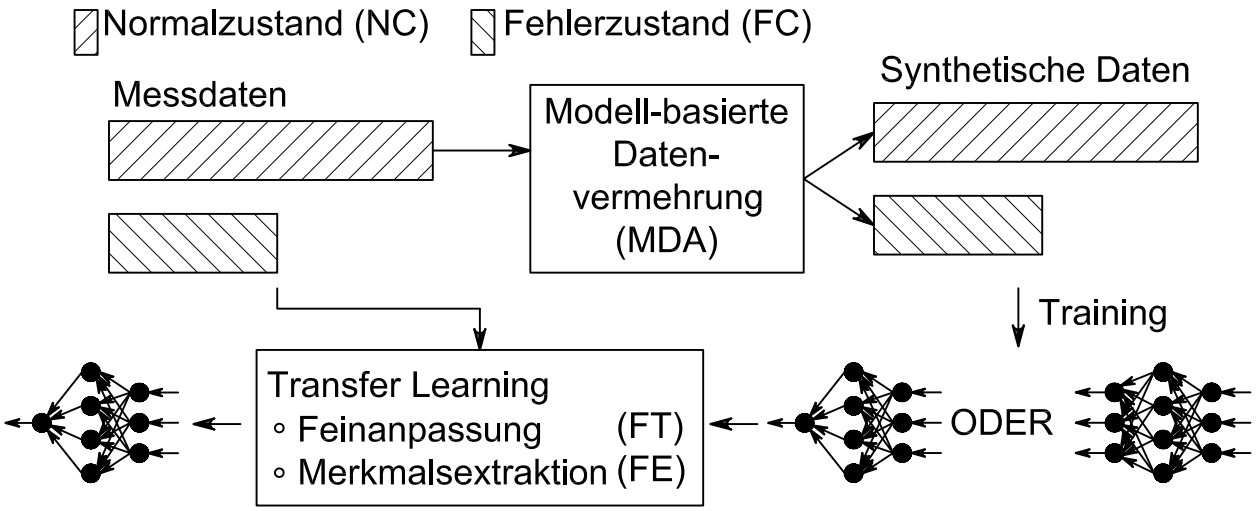

FIG. 2e

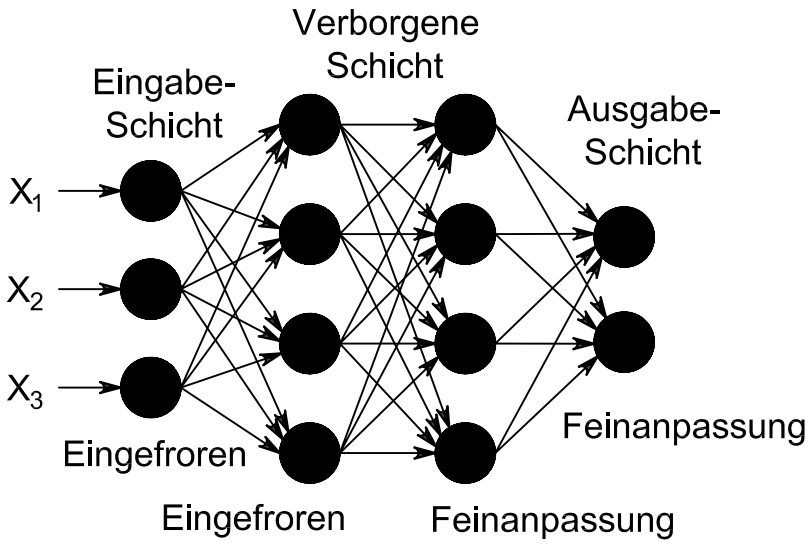

FIG. 2f

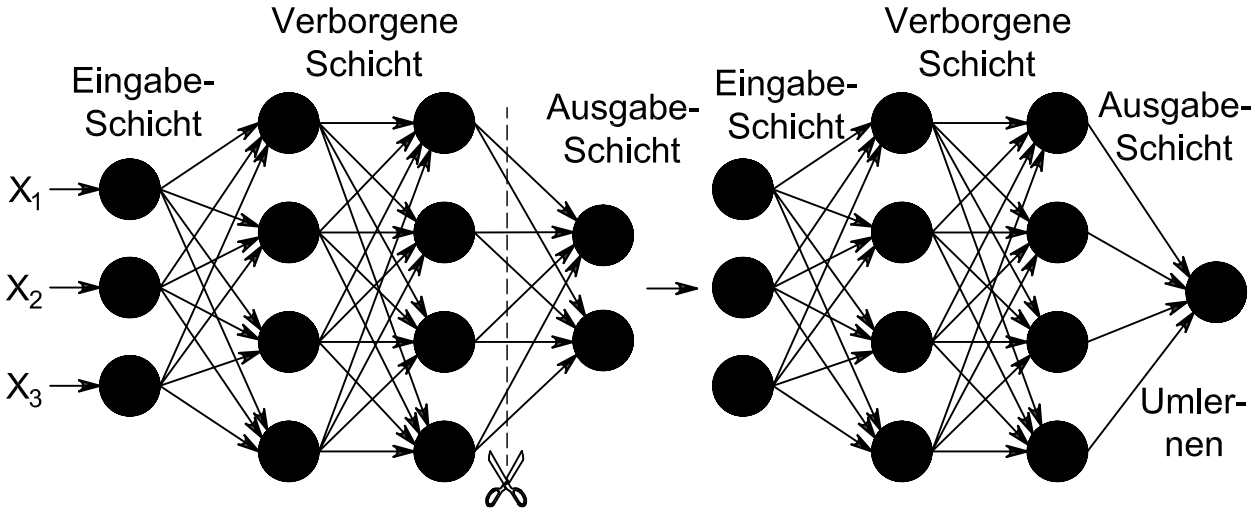

FIG. 2g

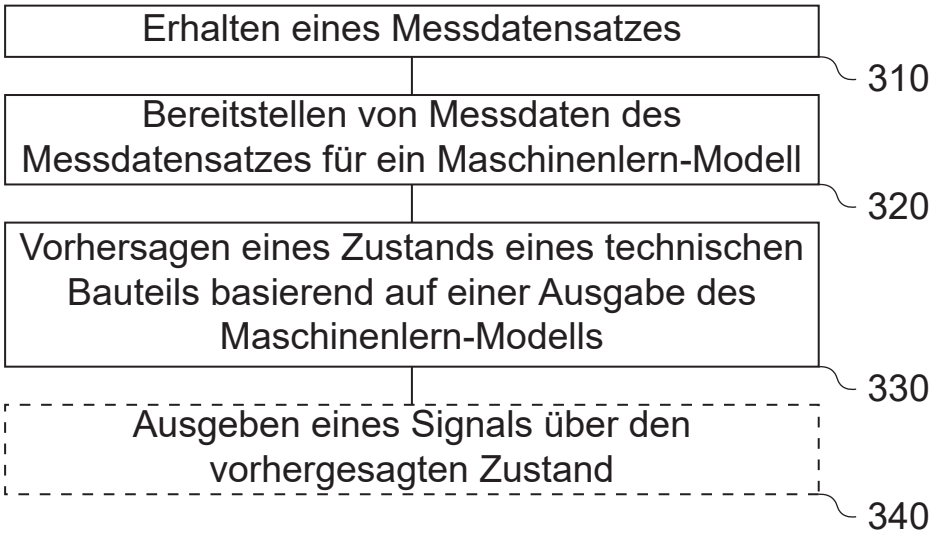
Erhalten eines Messdatensatzes
310
Bereitstellen von Messdaten des Messdatensatzes für ein Maschinenlern-Modell
320
Vorhersagen eines Zustands eines technischen Bauteils basierend auf einer Ausgabe des Maschinenlern-Modells
330
Ausgeben eines Signals über den vorhergesagten Zustand
340

Fig. 3a

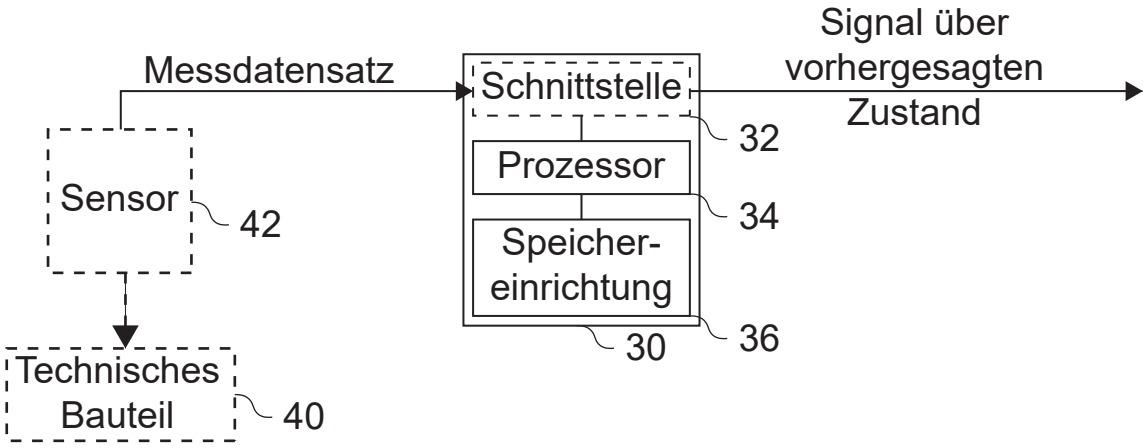
Messdatensatz
Schnittstelle
32
Prozessor
34
Speicher-einrichtung
36
30
Signal über vorhergesagten Zustand
Sensor
42
Technisches Bauteil
40

Fig. 3b